

Министерство науки и высшего образования Российской Федерации
федеральное государственное автономное образовательное учреждение
высшего образования
**«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ТОМСКИЙ ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ»**

Школа – Инженерная школа информационных технологий и робототехники
Направление подготовки – 09.04.01 «Информатика и вычислительная техника»
Отделение школы (НОЦ) – Отделение информационных технологий

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

| Тема работы |
|--|
| Разработка алгоритмов машинного обучения для автоматического описания рентгеновских изображений |

УДК 004.421:004.7.032.26:621.386.6:61

Студент

| Группа | ФИО | Подпись | Дата |
|--------|---------------|---------|------|
| 8BM83 | Скворцов А.В. | | |

Руководитель

| Должность | ФИО | Учёная степень, звание | Подпись | Дата |
|-----------|------------|------------------------|---------|------|
| Доцент | Друки А.А. | к.т.н. | | |

КОНСУЛЬТАНТЫ:

По разделу «Финансовый менеджмент»

| Должность | ФИО | Учёная степень, звание | Подпись | Дата |
|------------------|----------------|------------------------|---------|------|
| Доцент ОСГН ШБИП | Верховская М.В | к.э.н. | | |

По разделу «Социальная ответственность»

| Должность | ФИО | Учёная степень, звание | Подпись | Дата |
|--------------------|---------------|------------------------|---------|------|
| Профессор ОКД ШБИП | Федоренко О.Ю | д.т.н. | | |

ДОПУСТИТЬ К ЗАЩИТЕ:

| Руководитель ООП | ФИО | Ученая степень, звание | Подпись | Дата |
|------------------|-------------|------------------------|---------|------|
| Профессор | Спицын В.Г. | д.т.н. | | |

ПЛАНИРУЕМЫЕ РЕЗУЛЬТАТЫ ОБУЧЕНИЯ

по направлению 09.04.01 Информатика и вычислительная техника

| Код компетенции | Наименование компетенции |
|---|---|
| Универсальные компетенции | |
| УК(У)-1 | Способен осуществлять критический анализ проблемных ситуаций на основе системного подхода, вырабатывать стратегию действий |
| УК(У)-2 | Способен управлять проектом на всех этапах его жизненного цикла |
| УК(У)-3 | Способен организовывать и руководить работой команды, вырабатывая командную стратегию для достижения поставленной цели |
| УК(У)-4 | Способен применять современные коммуникативные технологии, в том числе на иностранном (-ых) языке (-ах), для академического и профессионального взаимодействия |
| УК(У)-5 | Способен анализировать и учитывать разнообразие культур в процессе межкультурного взаимодействия |
| УК(У)-6 | Способен определять и реализовывать приоритеты собственной деятельности и способы ее совершенствования на основе самооценки |
| Общепрофессиональные компетенции | |
| ОПК(У)-1 | Способен самостоятельно приобретать, развивать и применять математические, естественно-научные, социально-экономические и профессиональные знания для решения нестандартных задач, в том числе в новой или незнакомой среде и в междисциплинарном контексте |
| ОПК(У)-2 | Способен разрабатывать оригинальные алгоритмы и программные средства, в том числе с использованием современных интеллектуальных технологий, для решения профессиональных задач |
| ОПК(У)-3 | Способен анализировать профессиональную информацию, выделять в ней главное, структурировать, оформлять и представлять в виде аналитических обзоров с обоснованными выводами и рекомендациями |
| ОПК(У)-4 | Способен применять на практике новые научные принципы и методы исследований |
| ОПК(У)-5 | Способен разрабатывать и модернизировать программное и аппаратное обеспечение информационных и автоматизированных систем |
| ОПК(У)-6 | Способен разрабатывать компоненты программно-аппаратных комплексов обработки информации и автоматизированного проектирования |

| | |
|-------------------------------------|---|
| ОПК(У)-7 | Способен адаптировать зарубежные комплексы обработки информации и автоматизированного проектирования к нуждам отечественных предприятий |
| ОПК(У)-8 | Способен осуществлять эффективное управление разработкой программных средств и проектов |
| Профессиональные компетенции | |
| ПК(У)-1 | Способен разрабатывать и администрировать системы управления базами данных |
| ПК(У)-2 | Способен проектировать сложные пользовательские интерфейсы |
| ПК(У)-3 | Способен управлять процессами и проектами по созданию (модификации) информационных ресурсов |
| ПК(У)-4 | Способен осуществлять руководство разработкой комплексных проектов на всех стадиях и этапах выполнения работ |
| ПК(У)-5 | Способен проектировать и организовывать учебный процесс по образовательным программам с использованием современных образовательных технологий |

Министерство науки и высшего образования Российской Федерации
федеральное государственное автономное образовательное учреждение
высшего образования
**«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ТОМСКИЙ ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ»**

Школа – Инженерная школа информационных технологий и робототехники
Направление подготовки – 09.04.01 «Информатика и вычислительная техника»
Отделение школы (НОЦ) – Отделение информационных технологий

УТВЕРЖДАЮ:
Руководитель ООП

(Подпись) (Дата) (Ф.И.О.)

ЗАДАНИЕ
на выполнение выпускной квалификационной работы

В форме:

| |
|--------------------------|
| Магистерской диссертации |
|--------------------------|

Студенту: (бакалаврской работы, дипломного проекта/работы, магистерской диссертации)

| Группа | ФИО |
|--------|---------------------------------|
| 8ВМ83 | Скворцову Александру Вадимовичу |

Тема работы:

| | |
|--|--|
| Разработка алгоритмов машинного обучения для автоматического описания рентгеновских изображений | |
| Утверждена приказом директора (дата, номер) | |

| | |
|--|--|
| Срок сдачи студентом выполненной работы: | |
|--|--|

ТЕХНИЧЕСКОЕ ЗАДАНИЕ:

| | |
|--|---|
| Исходные данные к работе <i>(наименование объекта исследования или проектирования; производительность и/или нагрузка; режим работы (непрерывный, периодический, циклический и т. д.); вид сырья или материал изделия; требования к продукту, изделию или процессу; особые требования к особенностям функционирования (эксплуатации) объекта или изделия в плане безопасности эксплуатации, влияния на окружающую среду, энергозатратам; экономический анализ и т. д.).</i> | Предметом исследования являются нейронные сети, используемые в задачах классификации изображений. |
| Перечень подлежащих исследованию, проектированию и разработке вопросов <i>(аналитический обзор по литературным источникам с целью выяснения достижений мировой науки техники в рассматриваемой области; постановка задачи исследования, проектирования, конструирования;</i> | <ul style="list-style-type: none">– Обзор литературных источников.– Поиск или формирование выборок данных.– Обучение нейронных сетей– Сравнительный анализ результатов работы обученных нейронных сетей.– Социальная ответственность. |

| | |
|--|---|
| содержание процедуры исследования, проектирования, конструирования; обсуждение результатов выполненной работы; наименование дополнительных разделов, подлежащих разработке; заключение по работе). | – Финансовый менеджмент, ресурсоэффективность и ресурсосбережение. – Заключение. |
| Перечень графического материала (с точным указанием обязательных чертежей) | |

Консультанты по разделам выпускной квалификационной работы

с указанием разделов)

| Раздел | Консультант |
|---|--|
| Основная часть | Доцент ОИТ ИШИТР, к.т.н., Друки А.А. |
| Финансовый менеджмент, ресурсоэффективность и ресурсосбережение | Доцент ОСГН ШБИП к.э.н., Верховская М.В |
| Социальная ответственность | Профессор ОКД ШБИП д.м.н., Федоренко О.Ю |
| Английский язык | Старший преподаватель Розанова Я.В. |

Названия разделов, которые должны быть написаны на русском и иностранном языках:

Аналитический обзор

Материалы и методы

Результаты экспериментов

Финансовый менеджмент, ресурсоэффективность и ресурсосбережение

Социальная ответственность

| | |
|---|--|
| Дата выдачи задания на выполнение выпускной квалификационной работы по линейному графику | |
|---|--|

Задание выдал руководитель / консультант (при наличии):

| Должность | ФИО | Ученая степень, звание | Подпись | Дата |
|-----------|-------------|------------------------|---------|----------|
| Доцент | Друки А.А., | к.т.н. | | 01.03.21 |

Задание принял к исполнению студент:

| Группа | ФИО | Подпись | Дата |
|--------|---------------|---------|----------|
| 8BM83 | Скворцов А.В. | | 01.03.21 |

**ЗАДАНИЕ ДЛЯ РАЗДЕЛА
«ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И
РЕСУРСОСБЕРЕЖЕНИЕ»**

Студенту:

| Группа | ФИО |
|--------|------------------------------|
| 8BM92 | Скворцов Александр Вадимович |

| Школа | ИШИТР | Отделение школы (НОЦ) | ОИТ |
|---------------------|--------------|---------------------------|---|
| Уровень образования | магистратура | Направление/специальность | 09.04.01 «Информатика и вычислительная техника» |

Исходные данные к разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»:

| | |
|--|---|
| 1. Стоимость ресурсов научного исследования (НИ): материально-технических, энергетических, финансовых, информационных и человеческих | Оклад инженера – 22 695,68 руб. Оклад руководителя – 35111,5 руб. |
| 2. Нормы и нормативы расходования ресурсов | Районный коэффициент 30%; Коэффициент дополнительной заработной платы 12%; Накладные расходы 16%. |
| 3. Используемая система налогообложения, ставки налогов, отчислений, дисконтирования и кредитования | Коэффициент отчислений на уплату во внебюджетные фонды 30% |

Перечень вопросов, подлежащих исследованию, проектированию и разработке:

| | |
|--|---|
| 1. Оценка коммерческого и инновационного потенциала НТИ | - разработка графика Ганта. |
| 2. Разработка устава научно-технического проекта | -Анализ конкурентных технических решений |
| 3. Планирование процесса управления НТИ: структура и график поведения, бюджет, риски и организация закупок | накладные расходы. |
| 4. Определение ресурсной, финансовой, экономической эффективности | - Определение потенциального эффекта исследования |

Перечень графического материала (с точным указанием обязательных чертежей):

| |
|---|
| 1. «Портрет» потребителя результатов НТИ |
| 2. Сегментирование рынка |
| 3. Оценочная карта конкурентных технических решений |
| 4. Диаграмма FAST |
| 5. Матрица SWOT |
| 6. График проведения и бюджет НТИ |
| 7. Оценка ресурсной, финансовой и экономической эффективности НТИ |
| 8. Потенциальные риски |

Дата выдачи задания для раздела по линейному графику

Задание выдал консультант:

| Должность | ФИО | Ученая степень, звание | Подпись | Дата |
|------------------|----------------|------------------------|---------|----------|
| Доцент ОСГН ШБИП | Верховская М.В | к.э.н | | 01.03.21 |

Задание принял к исполнению студент:

| Группа | ФИО | Подпись | Дата |
|--------|---------------|---------|----------|
| 8BM92 | Скворцов А.В. | | 01.03.21 |

**ЗАДАНИЕ ДЛЯ РАЗДЕЛА
«СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ»**

Студенту:

| | |
|---------------|------------------------------|
| Группа | ФИО |
| 8BM93 | Скворцов Александр Вадимович |

| | | | |
|----------------------------|--|----------------------------------|---|
| Школа | Инженерная школа информационных технологий и робототехники | Отделение (НОЦ) | Информационных технологий |
| Уровень образования | Магистратура | Направление/специальность | 09.04.01 Информатика и вычислительная техника |

Тема ВКР:

| Разработка алгоритмов машинного обучения для автоматического описания рентгеновских изображений | |
|---|---|
| Исходные данные к разделу «Социальная ответственность»: | |
| 1. Характеристика объекта исследования (вещество, материал, прибор, алгоритм, методика, рабочая зона) и области его применения | <p>Целью работы является создание автоматической системы анализа рентгенологических изображений. Основная работа с системой и работа по её созданию производится с использованием персонального компьютера в жилом помещении.</p> <p>Характеристика помещения, где проводились работы по ВКР: ширина комнаты составляет $b = 4.5$ м, длина $a = 6$ м, высота $H = 2.8$ м. Площадь помещения будет составлять $S = ab = 27$ м², объем $V = abh = 81.4$ м³; присутствует окно, через которое может производиться вентиляция помещения, принудительная вентиляция отсутствует; в зимнее время помещение отапливается; в помещении используется комбинированное освещение.</p> |
| Перечень вопросов, подлежащих исследованию, проектированию и разработке: | |
| 1. Правовые и организационные вопросы обеспечения безопасности: <ul style="list-style-type: none"> — специальные (характерные при эксплуатации объекта исследования, проектируемой рабочей зоны) правовые нормы трудового законодательства; — организационные мероприятия при компоновке рабочей зоны. | <p>Работа над системой регулируется следующими нормативно-правовыми актами: трудовой кодекс Российской Федерации от 30.12.2001 N 197-ФЗ (ред. от 09.03.2021), СанПиН 1.2.3685-21, ТОИ Р-45-084-01, ГОСТ 12.2.032-78, ГОСТ 12.0.003-2015, СанПиН 2.2.4.548-96, СП 52.13330.2016, СН 2.2.4/2.1.8.562-96, ТОИ Р-45-084-01, ГОСТ 22269-76, ГОСТ Р 50923-96, ГОСТ 12.1.030-81, ГОСТ 12.1.038-82:</p> |
| 2. Производственная безопасность: 2.1. Анализ выявленных вредных и опасных факторов 2.2. Обоснование мероприятий по снижению воздействия | <p>Вредные факторы:</p> <ol style="list-style-type: none"> 1. Электромагнитные поля; 2. Электростатические поля; 3. Шум и вибрации; 4. Отклонения показателей микроклимата от нормы в помещении; 5. Недостаточная освещенность рабочей зоны; 6. Психофизиологические факторы (монотонность труда, нервно-психические перегрузки, перенапряжение зрительных анализаторов). <p>Опасные факторы:</p> <ol style="list-style-type: none"> 1. Поражение электрическим током; 2. Короткое замыкание; |

| | |
|--|---|
| | 3. Статическое электричество: |
| 3. Экологическая безопасность: | Негативное влияние объекта исследования на литосферу происходит при утилизации компьютера и периферийных устройств (принтеры, МФУ, веб-камеры, наушники, колонки, телефоны), аккумуляторных батарей, люминесцентных ламп, макулатуры. Вышеобозначенные факторы регулируются ГОСТ 17.4.3.04-85, ГОСТ Р 53692-2009 |
| 4. Безопасность в чрезвычайных ситуациях: | Возможными чрезвычайными ситуациями при разработке устройства являются пожары, грозы, ураганы, оползни. Вероятные ЧС, инициируемые объектом исследования: пожары. Этот фактор регулируется ГОСТ 12.1.004-91. |

| | |
|--|------------|
| Дата выдачи задания для раздела по линейному графику | 01.03.2021 |
|--|------------|

Задание выдал консультант:

| Должность | ФИО | Ученая степень, звание | Подпись | Дата |
|--------------------|-------------------------|-------------------------|---------|------------|
| Профессор ОКД ШБИП | Федоренко Ольга Юрьевна | Доктор медицинских наук | | 01.03.2021 |

Задание принял к исполнению студент:

| Группа | ФИО | Подпись | Дата |
|--------|------------------------------|---------|------------|
| 8ВМ93 | Скворцов Александр Вадимович | | 01.03.2021 |

РЕФЕРАТ

Выпускная квалификационная работа содержит пояснительную записку на 127 листах, включает 48 рисунков, 20 таблиц, 51 источник литературы, 1 приложение.

Ключевые слова: распознавание образов, свёрточные нейронные сети, рентгенология, машинное обучение.

Объектом исследования являются: нейронные сети для классификации изображений.

Цель работы: реализация нескольких алгоритмов машинного обучения для автоматического анализа рентгеновских изображений, сравнение результатов их работы между собой и с аналогами.

Задачами исследования являются:

1. Анализ подходов к решению задачи автоматического описания рентгенологических изображений;
2. Поиск и анализ датасетов;
3. Реализация и тестирование выбранных архитектур нейронных сетей;
4. Реализация и тестирование выбранных способов предобработки изображений;
5. Сравнение результатов работы всех реализованных алгоритмов между собой и с аналогами;

В результате проведённых экспериментов в соответствии с поставленными задачами было проведено сравнение двух типов архитектур, 4 архитектур, одного ансамбля нейронных сетей. Был оценен эффект трёх различных способов предобработки изображений на результаты классификации и выделяемые на изображениях признаки. Было произведено сравнение обученных нейронных сетей между собой и с аналогами. Был произведён анализ наиболее распространённого набора данных рентгеновских снимков грудной клетки, сформулированы его недостатки. Были сформулированы рекомендации к дальнейшему улучшению работы аналогичных систем.

ОПРЕДЕЛЕНИЯ, ОБОЗНАЧЕНИЯ, СОКРАЩЕНИЯ

CNN – convolutional neural network

ЗП – заработная плата.

ПР – прибыль

РФ — Российская Федерация.

ГОСТ — Государственный стандарт.

СНиП – Строительные нормы и правила.

СН – строительные нормы.

СП – строительные правила.

СанПиН – Санитарные правила, нормы, правила и нормы, гигиеническиенорматив

| | |
|--|----|
| ВВЕДЕНИЕ | 6 |
| ГЛАВА 1. АНАЛИТИЧЕСКИЙ ОБЗОР | 7 |
| 1.1 Медицинские аспекты. | 7 |
| 1.1.1 Актуальность классической рентгенографии | 7 |
| 1.1.2 Использование искусственного интеллекта в автоматическом анализе рентгенологических изображений, текущее состояние..... | 9 |
| 1.2. Описание основных алгоритмов | 10 |
| 1.2.2 Мультиклассификация | 10 |
| 1.2.3 Классификация по нескольким меткам. | 11 |
| 1.2.4 Полносвязные и сверточные нейронные сети. | 11 |
| 1.2.5 Трансферное обучение. | 14 |
| 1.2.6 Карты активации классов..... | 15 |
| 1.2.7 Преобразование Фурье | 16 |
| 1.3 Существующие алгоритмы автоматического анализа рентгенологических изображений. | 18 |
| 2. МАТЕРИАЛЫ И МЕТОДЫ..... | 23 |
| 2.1 Используемые технологии | 23 |
| 2.1.1 Keras | 23 |
| 2.1.2 OpenCV | 24 |
| 2.1.3 TensorFlow | 24 |
| 2.1.4 NumPy | 24 |
| 2.2 Используемые архитектуры нейронных сетей. | 25 |
| 2.3 Используемые наборы данных. | 27 |
| 2.3.1 NIH Chest X-Ray Dataset..... | 27 |
| ГЛАВА 3 РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТОВ. | 29 |
| 3.1 Параметры обучения..... | 29 |
| 3.2 Обучение со случайной инициализацией весов. | 29 |
| 3.3 Трансферное обучение с весами, без модификации весов ImageNet | 32 |
| 3.3.1 Описание экспериментов | 32 |
| 3.3.2 Анализ метрик точности троичных классификаторов по классам. | 36 |
| 3.3.3 Анализ карт активаций классов троичных классификаторов | 39 |
| 3.3.4 Ансамбль троичных классификаторов. | 44 |
| 3.4 Трансферное обучение с изменением весов ImageNet..... | 45 |
| 3.4.1 Описание экспериментов с VGG19..... | 45 |

| | |
|--|----|
| 3.4.2 Анализ метрик точности мультиклассификаторов VGG19 по классам. | 49 |
| 3.4.3 Анализ карт активаций классов мультиклассификаторов VGG19 | 55 |
| 3.3.4 Описание экспериментов с мультиклассификаторами ResNet50 | 58 |
| 3.3.5 Анализ метрик точности по классам мультиклассификаторов на основе ResNet50 | 58 |
| 3.3.6 Анализ карт активаций классов классификаторов на основе ResNet50 | 60 |
| Обсуждение результатов. | 61 |
| ГЛАВА 4. Финансовый менеджмент, ресурсоэффективность и ресурсосбережение | 63 |
| 4.1 Предпроектный анализ | 63 |
| 4.1.1 Потенциальные потребители результатов исследования | 63 |
| 4.1.2 Анализ конкурентных решений | 64 |
| 4.1.3 SWOT-анализ | 64 |
| 4.1.4 Оценка готовности проекта к коммерциализации | 66 |
| 4.1.5 Цели и результаты проекта | 68 |
| 4.2 Планирование управления научно-техническим проектом | 69 |
| 4.2.1 План проекта | 69 |
| 4.2.2 Бюджет научного исследования | 70 |
| 4.2.3 Специальное оборудование для научных работ | 71 |
| 4.2.4 Основная заработная плата | 72 |
| 4.2.5 Дополнительная заработная плата научно-производственного персонала | 74 |
| 4.2.6 Отчисления на социальные нужды | 75 |
| 4.2.7 Накладные расходы | 76 |
| 4.2.8 Формирование бюджета затрат научно-исследовательского проекта | 77 |
| 4.3 Оценка научного уровня | 78 |
| Выводы по разделу. | 81 |
| ГЛАВА 5. СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ | 82 |
| 5.1 Правовые аспекты обеспечения безопасности | 83 |
| 5.2 Эргономические требования к рабочему месту | 83 |
| 5.3 Производственная безопасность | 84 |
| 5.3.1 Вредные производственные факторы | 85 |
| 5.3.2 Опасные производственные факторы | 91 |
| 5.4 Экологическая безопасность | 92 |

| | |
|---|-----|
| 5.5 Безопасность в чрезвычайных ситуациях | 93 |
| Выводы по разделу | 95 |
| ЗАКЛЮЧЕНИЕ | 95 |
| ПРИЛОЖЕНИЕ А | 101 |

ВВЕДЕНИЕ

Актуальность работы. В настоящее время развитие технологий искусственного интеллекта и машинного обучения, а также накопление больших объемов медицинских изображений открывают возможность создания систем автоматического анализа медицинских изображений.

Рентген грудной клетки - это одно из самых простых и распространенных обследований, применяющихся на данный момент. Его автоматизация значительно снизит нагрузку на рентгенологов, позволит оценивать качество их работы и снизит вероятность врачебных ошибок.

Цель работы. целью данной работы является реализация нескольких алгоритмов машинного обучения для автоматического анализа рентгеновских изображений, сравнение результатов их работы между собой и с аналогами.

Задачами исследования является:

6. Анализ подходов к решению задачи автоматического описания рентгенологических изображений;
7. Поиск и анализ датасетов;
8. Реализация и тестирование выбранных архитектур нейронных сетей;
9. Реализация и тестирование выбранных способов предобработки изображений;
10. Сравнение результатов работы всех реализованных алгоритмов между собой и с аналогами;

Предмет исследования. Предмет исследования - нейронные сети, используемые для классификации изображений.

ГЛАВА 1. АНАЛИТИЧЕСКИЙ ОБЗОР

1.1 Медицинские аспекты.

1.1.1 Актуальность классической рентгенографии

В настоящее время широко распространены методы лучевой диагностики, например, компьютерная томография, магнитно-резонансная томография, позитронно-эмиссионная томография. Эти методы неразрушающего послойного исследования внутреннего строения человеческого тела обладают высокой диагностической информативностью. Тем не менее, использование этих методов имеет несколько недостатков. Они требуют дорогого, сложного в обслуживании оборудования, с высоким потреблением энергии, специализированного программного обеспечения и часто создают высокую лучевую нагрузку. Все это уменьшает доступность обследований и перспективы их более широкого использования. В следствие этого, в настоящее время, эти методы визуализации используются только после классической рентгенографии, если возникает подозрение на заболевание

Рентгенография это исследование внутренней структуры объектов, с помощью квантов света высокой энергии (рентгеновского излучения), способных проходить объекты насквозь, создавая картину из теней, зависящих от проницаемости элементов объекта для рентгеновского излучения, что чаще всего, означает более высокую плотность. Рентген грудной клетки дает изображение грудной клетки, легких, сердца, дыхательных путей и кровеносных сосудов в двумерной проекции. С помощью рентгеновского снимка грудной клетки квалифицированный радиолог может диагностировать такие состояния, как пневмония, пневмоторакс, интерстициальное заболевание легких, сердечная недостаточность, перелом костей, грыжа пищеводного отверстия диафрагмы и т. Большим преимуществом рентгеновского излучения является низкая стоимость и простота использования. Рентген грудной клетки занимает всего несколько минут, а результат обычно проявляется в течение получаса. Современные аппараты цифровой рентгенографии (ДР) вполне доступны даже в неосвоенных регионах и способны работать от маломощного источника энергии, в том числе

и мобильного.

По причинам указанным выше рентген грудной клетки является одним из распространенных радиологических исследований в больницах и стандартным методом скрининга при физическом обследовании. Крупная больница обычно производит более 40 000 рентгеновских снимков грудной клетки в год только амбулаторно. Например, в 2014 году в Китае рентгенографию прошли более трехсот миллионов человек. При этом это число постоянно увеличивается, что приводит к сотням миллионов новых рентгеновских снимков грудной клетки в год. Отсутствие квалифицированных радиологов для просмотра этих рентгеновских снимков является серьезной проблемой в Китае. Результат анализа рентгеновских снимков грудной клетки в значительной степени зависит от опыта радиологов, поскольку изображение не имеет информации о глубине, а перекрытие различных частей тела может скрыть пораженные ткани. Кроме того, многие изображения трудно читать, когда поражения малоконтрастны или перекрываются с крупными легочными сосудами.

Неопытные радиологи иногда не уверены в своем диагнозе, но у них может не быть возможности обсудить это с другими. Поскольку рентгеновское изображение обычно содержит множественные патологии, рентгенологам сложно поставить диагноз за короткое время. Каждый рентген грудной клетки занимает у обученного врача рентгенолога несколько минут, кроме того, уходит дополнительное время на то, что бы просмотреть и написать отчет. В следствии этого многим рентгенологам приходится работать сверхурочно, что увеличивает вероятность ошибочного диагноза из-за истощения. В результате высока вероятность ошибочного рентгена. Сообщается, что от 20% до 50% узелков в легких не обнаруживаются или ошибочно диагностируются, при рентгенографии грудной клетки, в то время, как большинство из них может быть обнаружено ретроспективно или вторым рецензентом. [1, 2, 3].

1.1.2 Использование искусственного интеллекта в автоматическом анализе рентгенологических изображений, текущее состояние.

Развитие искусственного интеллекта (ИИ) в сочетании с накоплением большого количества медицинских изображений открывает новую возможность для создания системы на основе ИИ, системы компьютерной диагностики (CAD), для автоматического анализа таких рентгеновских снимков грудной клетки. Благодаря недавнему успеху в области глубинного обучения автоматическая диагностика заболеваний с помощью методов компьютерного зрения может помочь рентгенологам обнаруживать и идентифицировать потенциальные патологии, а также способствовать дальнейшему продвижению исследований и приложений для систем компьютерной диагностики.

CAD охватывают многие медицинские проблемы, такие, как автоматическое определение позвонков, автоматическая оценка содержания кальция в коронарных артериях, обнаружение лимфатических узлов и классификация интерстициальных заболеваний легки. Однако, самые последние системы CAD, чаще всего, зависят от изображений магнитно-резонансной томографии (МРТ) с высоким разрешением или компьютерной томографии (КТ), игнорируя при этом обычную рентгенографию.

Большинство существующих работ в указанной области формулируют задачу, как задачу классификации изображений с несколькими метками, например, 14 типов патологий в наборе данных Chest X-ray 14. В настоящее время значительный прогресс был достигнут за счет использования последних архитектур глубоких сверточных нейронных сетей, в качестве моделей классификации. Хотя, в последние годы были получены многообещающие результаты, трудности моделирования тонких межклассовых различий и больших внутриклассовых различий по-прежнему создают серьезные проблемы. Например, внешний вид (например, светлая тень в виде облака) узлового образования и объёмного образования очень похожи и могут перекрывать друг друга в некоторых областях грудной клетки. Поскольку существующие сети на

основе CNN в основном предназначены для классификации общих изображений с большими визуальными различиями, такими, как, например, люди и самолет в ImageNetdataset, а не рентгеновских изображений, эти мелкозернистые патологии трудно различить. Кроме того, на рентгеновских снимках часто можно наблюдать разнообразные симптомы туберкулеза, , которые сложно идентифицировать не только автоматическим алгоритмам, но даже опытным рентгенологам. [1, 4, 5, 6, 7, 8, 9].

1.2. Описание основных алгоритмов

1.2.1. Постановка проблемы классификации

Формальная постановка проблемы классификации следующая: пусть X - множество описаний объектов, Y - конечный набор номеров классов. Имеется неизвестная целевая зависимость $y^*: X \rightarrow Y$. Её значения известны только на объекте итоговой обучающей выборки $X_m = \{(x_1, y_1), \dots, (x_m, y_m)\}$. Требуется построить алгоритм $a^*: X \rightarrow Y$, способный классифицировать произвольный объект $x \in X$. Признак - это отображение $f: X \rightarrow D_f$, где D_f - множество допустимых значений признака. Если даны признаки f_1, \dots, f_n , то вектор $x = (f_1(x), \dots, f_n(x))$ называется описанием признаков объекта $x \in X$. Описание характеристик можно отождествить с самими объектами. В этом случае множество $X = D_{f_1} \times \dots \times D_{f_n}$ называется пространством признаков. В зависимости от типа набора D_f , функции делятся на следующие типы [10]:

1. бинарный признак: $D_f = \{0, 1\}$;
2. номинальный признак: D_f - конечное множество;
3. порядковый признак: D_f - конечный упорядоченный набор;
4. количественный признак: D_f - набор действительных чисел.

1.2.2 Мультиклассификация

Классификацию по нескольким классам не следует путать с классификацией по нескольким меткам, в которой экземпляру может быть сопоставлены несколько меток. В машинном обучении мультиклассовая или полиномиальная классификация - это проблема классификации экземпляров в один из трех или более классов (классификация экземпляров в один из двух

классов называется бинарной или двоичной классификацией) [11,12].

Хотя многие алгоритмы классификации (особенно полиномиальная логистическая регрессия) естественным образом допускают использование более двух классов, некоторые из них по своей природе являются бинарными алгоритмами. Существующие методы мультиклассовой классификации можно разделить на сведение к бинарной классификации и расширение бинарной классификации к мультиклассовой классификации. При сведении к работе нескольких бинарных классификаторов используются варианты обучения «один против одного» и «один против всех».

В качестве функций ошибок в нейронных сетях, используемых в мультиклассовой классификации, используется категориальная кросс-энтропия с функцией активации Softmax. Суммарная вероятность по всем классам при использовании этой функции равна 100 процентам [11,12].

1.2.3 Классификация по нескольким меткам.

Классификация по нескольким меткам - это обобщение мультиклассовой классификации до задачи с несколькими метками, у которых нет ограничений на то, скольким классам может быть отнесён экземпляр. Формально, классификация с несколькими метками - это проблема поиска модели, которая отображает входные данные X в двоичные векторы Y , присваивая значение 0 или 1 для каждого элемента в Y . Классификации с несколькими метками может быть сведена к бинарной классификации, мультиклассовой классификации, при которой каждая комбинация меток рассматривается как отдельный класс, ансамблю классификаторов [13,14].

В случае, если классификация по нескольким метками осуществляется одной нейронной сетью с несколькими выходами используется бинарная кросс-энтропия в качестве функции ошибки. При использовании этой функции ошибки значения вероятности принадлежности к классу в сумме не равны единице [13,14].

1.2.4 Полносвязные и сверточные нейронные сети.

Полносвязная нейронная сеть с прямой связью - это сеть, в которой

нейрон связан со всеми другими нейронами, расположенными в соседних слоях (см. Рисунок 1.1 ниже).

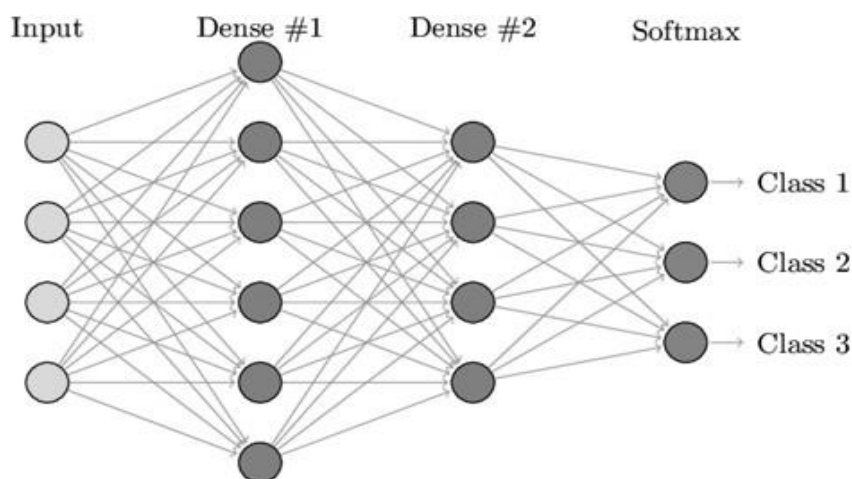


Рис. 1.1 Полносвязная нейронная сеть. В левой части изображения показан входной слой, на который поступает сигнал. Справа находятся два скрытых слоя, а крайний правый нейронный слой является выходным слоем [15,16].

Эта сеть способна решать как проблему распознавания нескольких классов, так и нескольких классов с несколькими метками [15,16].

При использовании нейронных сетей в таких задачах, как классификация изображений, восстановление изображения и тр.. возникает проблема обработки большого количества данных. Например, в известной нейронной сети ImageNet в полностью связанной архитектуре нейронной сети каждый нейрон будет иметь порядка $256 * 256 * 3 = 196608$ весов. Для полноценной классификации необходимо множество таких нейронов. Решением этой проблемы является использование нейронной сети специальной архитектуры, разработанной именно для классификации изображений - сверточной нейронной сети.

В своё время идея свёрточных нейронных сетей появилась после изучения зрительной коры. Сверточные нейронные сети показывают лучшие результаты распознавания изображений на данный момент.

Слои этой нейронной сети расположены в трех измерениях, характерных для формата RGB. Нейроны в слое связаны только с определенной областью в

предыдущем слое, а не со всеми, как в полностью связанной сети. Основными слоями, которые используются в сверточной сети, являются: сверточный слой; слой с понижающей дискретизацией и полностью связанный слой, представляющий полностью подключенную нейронную сеть, уже описанную выше [17].

Свёрточный слой - это основной слой в CNN. Этот слой основан на операции свертки, которая заключается в том, что небольшая матрица проходит по всем входным данным и осуществляет операцию свёртки. Операция свёртки в функциональном анализе, при применении к двум функциям возвращает третью функцию, соответствующую их взаимной корреляции. Операцию свёртки можно интерпретировать, как «схожесть» одной функции с отражённой и сдвинутой копией другой. Матрица, осуществляющая свёртку называется ядром свертки, ее веса при обучении называются изначально неизвестны и определяются при обучении. Её работа интерпретируется, как извлечение признаков [17].

Слой понижающей дискретизации или слой объединения(pooling) сокращает матрицу признаков до матрицы меньшего размера. Это преобразование выполняется на уникальных, непересекающихся областях. Обычно из прямоугольника 2x2 выбирается один пиксель, чаще всего, имеющий максимальное значение. Это удаляет мелкие детали. В данной операции используется не только поиск максимального значения, но также вычисление среднего значения или функции нормализации L2 [17].

В полносвязанном слое происходит вычисление по уже полученным из предыдущих слоёв данным вероятности принадлежности к классу [17].

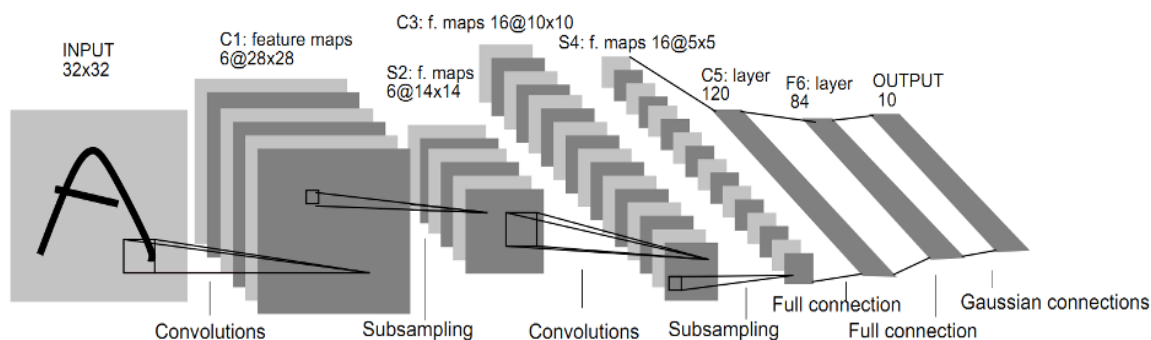


Рис. 1.2 Архитектура CNN

1.2.5 Трансферное обучение.

Идея трансферного обучения основана на том предположении, что знания, накопленные в модели, подготовленной для одной задачи, могут быть перенесены в другую модель, чтобы помочь в выполнении другой связанной задачи. Эксперименты показали, что точность нейронных сетей во время трансферного обучения увеличивалась, как в первую эпоху (до любого обучения, т. Е. По сравнению со стандартным случайным распределением весов), так и в конце процесса обучения [18,19,20].

Существуют различные подходы к переносному обучению. Наиболее широко используется тонкая настройка (точная настройка). В этом подходе используется предварительно обученная модель, в которой последние слои удаляются или повторно обучаются. В нейронных сетях базовые уровни сосредоточены на простых общих шаблонах, в то время, как последние уровни сосредоточены на более конкретных шаблонах для задач классификации или регрессии. Благодаря этому процессу разработчик может обучить новую модель в разумные сроки. Для глубокого обучения обычно требуются большие объемы помеченных данных. Во многих областях таких данных нет. Трансферное обучение может решить эту проблему. Например, команда Гарвардской медицинской школы создала модель, которая может на основе рентгенограмм грудной клетки прогнозировать смертность в долгосрочной перспективе, в том числе не связанную с раком. Несмотря на то, что у исследователей был набор

данных из примерно 50 000 изображений с метками, они не смогли обучить собственную сверточную нейронную сеть с нуля. Вместо этого они использовали подготовленную модель Inception-v4 (которая обучается на наборе данных из более чем 14 миллионов изображений ImageNet) и использовали трансферное обучение и незначительные архитектурные изменения для адаптации модели к своему набору данных. В результате их нейронная сеть научилась вычислять уровень риска по одному изображению груди пациента. [20].

1.2.6 Карты активации классов

По мере увеличения производительности систем машинного обучения интерпретируемость систем постепенно снижается. Эта тенденция более заметна в алгоритмах глубокого обучения, содержащих миллионы обучаемых параметров и сотни уровней. Это делает их чрезвычайно сложными для интерпретации по сравнению с базовыми алгоритмами машинного обучения, такими как линейная регрессия, K ближайших соседей, дерево решений и т. Д. Такие нейронные сети являются типичным примером черного ящика, который получает данные от пользователей и выдает результаты без какой-либо причинно-следственной информации, которая привела к такому выводу. В приложениях, где интерпретируемость результатов очень важна, свойства черного ящика препятствуют практическому использованию. Особенно это актуально в области медицины, где от диагноза зависит жизнь пациента. Предлагаются различные способы решения проблемы интерпретируемости и достижения уровня интерпретируемого ИИ. В случае CNN были обнаружены различные методы рендеринга, и одна из них - карты активации классов (CAM). Карта активации классов для конкретной категории указывает область, используемую CNN для определения класса. Нейронная сеть состоит из большого количества сверточных слоев и, непосредственно перед окончательным выходным слоем, выполняется глобальное среднее объединение. Полученные таким образом признаки подаются в полностью связанный слой, имеющий активацию softmax, которая дает желаемый выход. Мы можем определить важность областей изображения, проецируя веса выходного слоя на

карты сверточных объектов, полученные из последнего Сверточного слоя. Скалярное произведение извлеченных весов из последнего слоя и карты объектов рассчитывается для создания карты активации класса. Карта активации класса повышается с помощью билинейной интерполяции и накладывается на входное изображение, чтобы показать регионы, на которые смотрит модель CNN. (смотрите рисунок 3) [21,22].

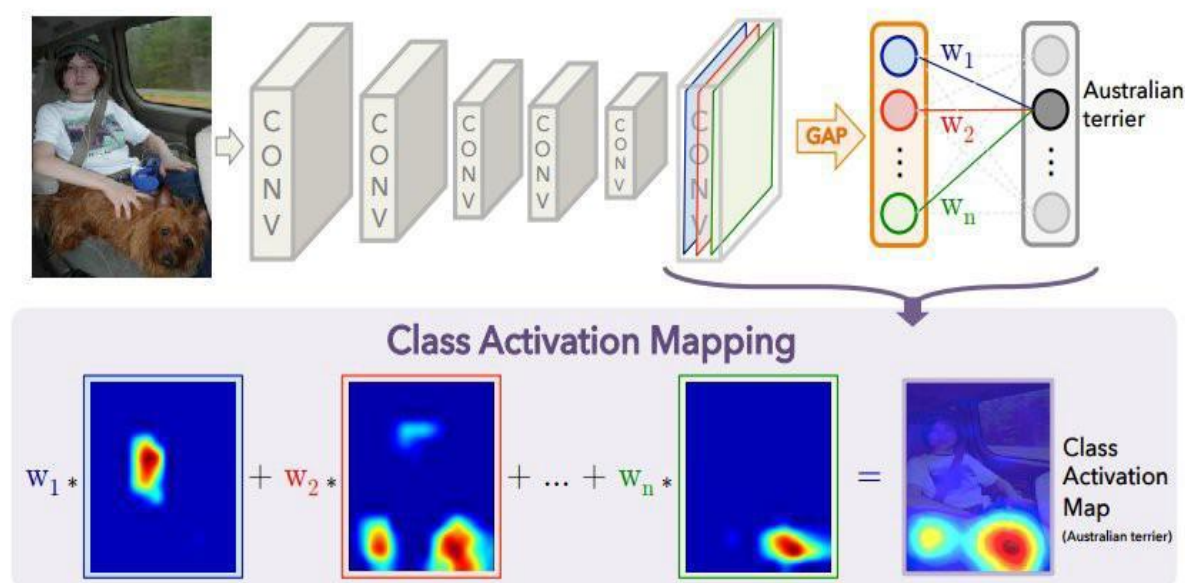


Рис. 1.3 Карты активаций классов, принцип работы.

1.2.7 Преобразование Фурье

Преобразование Фурье (\mathcal{F}) — операция, сопоставляющая одной функции вещественной переменной другую функцию, также вещественной переменной. Эта новая функция описывает коэффициенты («амплитуды») при разложении исходной функции на элементарные составляющие — гармонические колебания с разными частотами [23].

$$\hat{f}(\omega) = \frac{1}{(2\pi)^{n/2}} \int_{\mathbb{R}^n} f(x) e^{-ix \cdot \omega} dx.$$

Упрощённо можно сформулировать, что в случае с изображением оно позволяет

получить спектр, при котором большим однородным структурам будет соответствовать низкая частота, а большому числу небольших объектов высокие частоты (смотрите рисунок 1.4).




Рис.4 Пример преобразования фурие для цветного и чёрно-белого изображения.

Связь между пространственной областью и частотной областью может быть установлена с помощью теоремы о свертке. Теорема о свертке утверждает, что преобразование фурие свертки двух функций порождает поточечное умножение фурие преобразованных функций и наоборот. В более общем смысле, свертка в одной временной области равна поточечному умножению в частотной области [23].

Мы не можем не обратить внимание на интересный эффект сочетания преобразования фурие и свёрточных нейронных сетей. Если подать на вход свёрточной нейронной сети преобразованное изображение, то свёрточные блоки становятся блоками скалярного произведения с ядром свёртки подвергшимся обратному преобразованию фурие и наоборот, блоки обычного скалярного

произведение весов на входной Сигнал станут блоками свёртки с матрицей весов подвергшейся преобразованию фурье.

1.3 Существующие алгоритмы автоматического анализа рентгенологических изображений.

На данный момент существует множество различных подходов к задаче автоматического анализа рентгенологических изображений.


Wang предложил улучшение структуры путем дополнительной интеграции переходных слоев в CNN. Его сеть показывает хорошие результаты на самом большом наборе данных ChestX-ray 14 и является одной из основополагающих первых работ. [5, 24,25,26].

P. Rajpurkar предлагает использовать 121-слойную сверточную нейронную сеть DenseNet-121 в качестве основы, в сочетании с нелинейной функцией активации нейронов. Данная сеть получила название CheXNet . В диагностике пневмонии, ChexNet успешно превзошел средние показатели опытных


рентгенологов (смотрите рисунок 1.5)[5].




(a) Patient with multifocal community acquired pneumonia. The model correctly detects the airspace disease in the left lower and right upper lobes to arrive at the pneumonia diagnosis.



(b) Patient with a left lung nodule. The model identifies the left lower lobe lung nodule and correctly classifies the pathology.



(c) Patient with primary lung malignancy and two large masses, one in the left lower lobe and one in the right upper lobe adjacent to the mediastinum. The model correctly identifies both masses in the X-ray.



(d) Patient with a right-sided pneumothorax and chest tube. The model detects the abnormal lung to correctly predict the presence of pneumothorax (collapsed lung).



(e) Patient with a large right pleural effusion (fluid in the pleural space). The model correctly labels the effusion and focuses on the right lower chest.



(f) Patient with congestive heart failure and cardiomegaly (enlarged heart). The model correctly identifies the enlarged cardiac silhouette.

Рис. 1.5 CheXNet локализует патологии, которые он идентифицирует, используя карты активации классов, которые выделяют области рентгеновского снимка, которые наиболее сильно влияют на выбор нейронной сети для конкретной патологии.

Уао предлагает объединить CNN с рекуррентными нейронными сетями (RNN) для диагностики изображений грудной клетки, с учётом зависимостей между различными патологиями [27]. Его подход проиллюстрирован рисунком ниже.

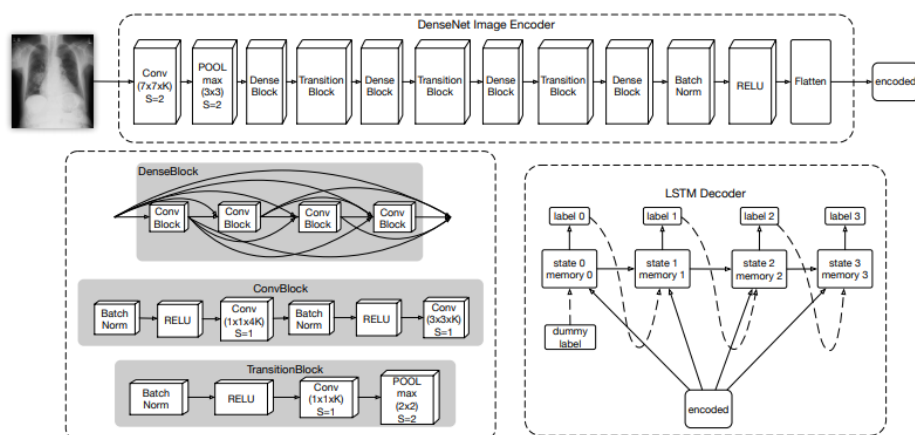


Рис. 1.6 Принципы работы системы Yao [27]

Liet al. использовал предварительно обученный ResNet для извлечения отдельных частей изображения, которые после подавались в сверточную сеть, чтобы получить карту вероятности для каждой патологии. Входное изображение в его сети сначала обрабатывается CNN. Далее, “Слой нарезки” генерирует на этой основе пакеты. Пакеты передаются в распознающую сверточную сеть для окончательной классификации (смотрите рисунок 1.7) [28].

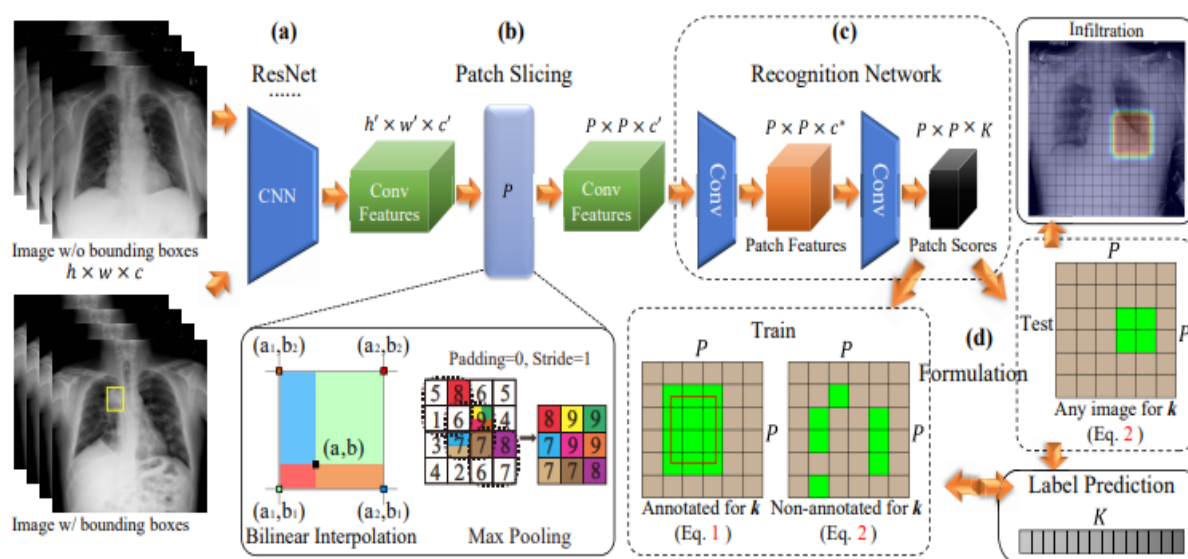


Рис. 1.7 Обзор модели Liet al.all [28].

Чжичэн Хуан и Донгмей Фу предлагают сверточную нейронную сеть с множественным вниманием для выявления патологий грудной клетки на рентгеновских снимках. Предложенный алгоритм состоит из трех частей: сверточная сеть для выделения признаков, которая подходит для пространственного прогнозирования и получения более конкретных областей для каждого класса; сеть с множественным вниманием для изучения отличительных признаков и модуль объединения. Схема Чжичэн Хуан и Донгмей Фу представлена на рисунке ниже. На нём (a) является входным изображением, (b) это FCN, которая может кодировать пространственную информацию в карту, (c) объединяет несколько уровней внимания для создания карт внимания для конкретных классов патологий, на уровне (d) происходит объединение, полученной от разных каналов для каждой категории; (e) представляет собой пул верхнего уровня, а (f) - классификационный уровень для прогнозирования каждого класса (смотрите рисунок 1.8) [9].

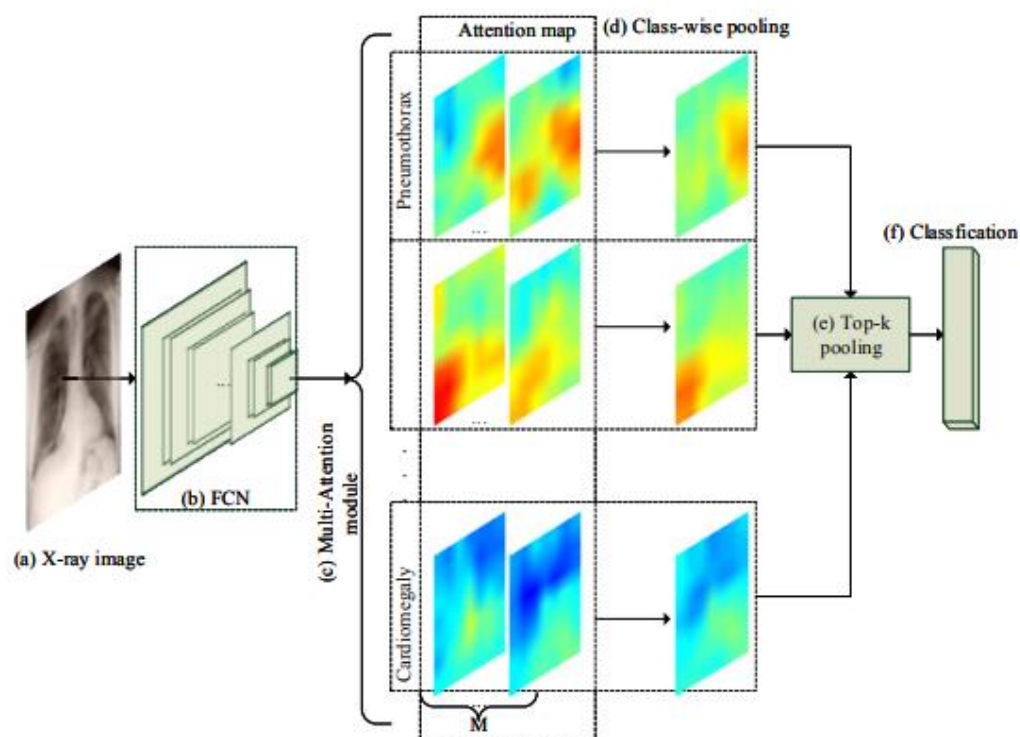
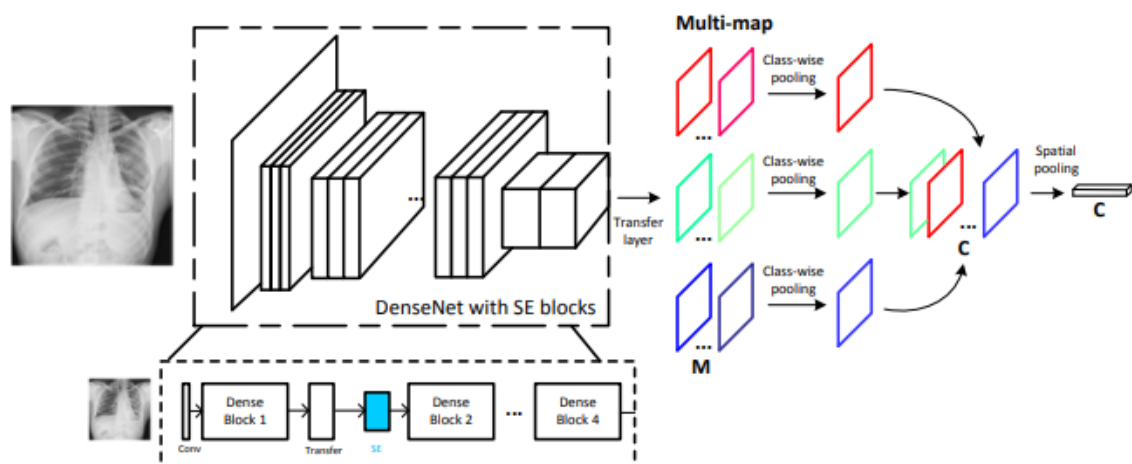


Рис. 1.8 Схема Чжичэн Хуан и Донгмей Фу [9].



Наконец, Yan et.al. были использованы комбинированные блоки сжатия и возбуждения с DenseNet для повышения производительности модели. (Рис 1.9). Кроме того, они так же использовали передачу карт признаков для локализации и выделения подозрительных областей [6].

Рис. 1.9 Усовершенствованная DenseNet, предложенная Yan et.al [6].

2. МАТЕРИАЛЫ И МЕТОДЫ

2.1 Используемые технологии

2.1.1 Keras

После анализа используемых на данный момент инструментов разработки нейросетевых алгоритмов было принято решение остановиться на использовании Keras. Keras — открытая нейросетевая библиотека, написанная на языке Python. Она представляет собой надстройку над фреймворками DeepLearning4j, TensorFlow и Theano. Нацелена на оперативную работу с сетями глубинного обучения, при этом спроектирована так, чтобы быть компактной, модульной и расширяемой. Эта библиотека содержит многочисленные реализации широко применяемых строительных блоков нейронных сетей, таких как слои, целевые и передаточные функции, оптимизаторы, и множество инструментов для упрощения работы с изображениями и текстом. Keras занимает второе место в рейтинге используемых фреймворков для глубокого обучения (смотрите рисунок 2.1) [29].




Рис. 2.1 Рейтинг используемых фреймворков для глубокого обучения

2.1.2 OpenCV

OpenCV (англ. *Open Source Computer Vision Library*, библиотека компьютерного зрения с открытым исходным кодом) – библиотека алгоритмов компьютерного зрения, обработки изображений и численных алгоритмов общего назначения с открытым кодом. Реализована на C/C++, также разрабатывается для Python, Java, Ruby, Matlab, Lua и других языков. Может свободно использоваться в академических и коммерческих целях. Также, данная библиотека содержит удобный функционал по работе с изображениями, алгоритмы их обработки, распознавания лиц и пр. Именно поэтому было принято решение об использовании OpenCV [30].

2.1.3 TensorFlow

TensorFlow – открытая программная библиотека для машинного обучения, разработанная компанией Google для решения задач построения и тренировки нейронной сети с целью автоматического нахождения и классификации образов. Основной API был реализован для Python. Этот фреймворк позволяет абстрагироваться от внутренних деталей машинного обучения и сосредоточиться непосредственно на решении задачи, позволяет создавать, обучать и использовать нейронные сети любого известного типа [31].

2.1.4 NumPy

NumPy это библиотека с открытым исходным кодом для языка программирования Python, которая предоставляет общие математические и числовые операции в виде пре-скомпилированных, быстрых функций. NumPy обеспечивает функциональность, которую можно сравнить с функционалом MatLab. NumPy предоставляет базовые методы для манипуляции с большими массивами и матрицами. SciPy (Scientific Python) расширяет функционал numpy за счёт таких алгоритмов, как минимизация, преобразование Фурье, регрессия [32].

2.2 Используемые архитектуры нейронных сетей.

Классификаторы, используемые в нашей работе основывались на двух известных архитектурах нейронных сетей VGG19 и Resnet50.

VGGNet возникла из-за необходимости уменьшить количество параметров в слоях свёртки и сократить время обучения, для этого в ней впервые были применены ядра свёртки фиксированного размера 3×3 [33].

ResNet — это сокращенное название для Residual Network (дословно — «остаточная сеть»). В ней используются соединения быстрого доступа (shortcut connections), которые пропускают один или несколько слоев и выполняют сопоставление идентификаторов [33].

Примеры архитектур VGGNet и ResNet приведены ниже.



Рис. 2.2 Архитектуры VGGNet и ResNet

2.3 Используемые наборы данных.

2.3.1 NIH Chest X-Ray Dataset

В нашей работе мы использовали “National Institutes of Health Chest X-Ray Dataset”. Набор данных основан на данных из Клинического центра Национального Института Здоровья США. Набор данных ChestX-ray включает 112 120 рентгеновских изображений фронтального обзора 30 805 уникальных пациентов с текстовыми метками четырнадцати изображений болезней (где каждое изображение может иметь несколько меток), полученных из связанных радиологических отчетов с использованием обработки естественного языка. Четырнадцать патологий грудной клетки представленные в этом наборе данных включают: ателектаз, уплотнение, инфильтрацию, пневмоторакс, отек, эмфизему, фиброз, выпот, пневмонию, уплотнение плевры, кардиомегалию, узелковые образования, объёмные образования и грыжу пищеводного отверстия диафрагмы. Ожидается, что текстовые метки болезней будут иметь точность более 90% [34].

Примеры патологий из набора данных и распределение изображений по классам приведены на рисунках ниже.




Рис. 2.3 Изображения с патологиями из используемого набора данных “National Institutes of Health Chest X-Ray Dataset”




Рис. 2.4 Количество экземпляров патологий в наборе данных “National Institutes of Health Chest X-Ray Dataset”.

ГЛАВА 3 РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТОВ.

3.1 Параметры обучения.

Во всех экспериментах использовался собственный, разработанный под поставленную задачу скрипт, с функцией сохранения набора карт активации классов и результатов предсказания нейронной сети, через заданные промежутки, для последующего анализа.

Начальная скорость обучения экспериментально была подобрана, как 10(-6) и использовалась при обучении всех ниже описанных классификаторов. При более высокой начальной скорости обучения часто происходило изучение только одного класса. Вероятно, это связано с очень небольшими межклассовыми отличиями рентгенологических изображений.

Во всех случаях использовался оптимизатор Adam.

3.2 Обучение со случайной инициализацией весов.

Первой тестируемой архитектурой был Resnet глубиной 50 слоёв. Перед подачей в нейронную сеть производился поворот изображения на случайный угол и его сжатие до размера 224 на 224. Обучение проводилось в двух вариантах. В первом случае нейронная сеть училась распознавать 14 классов патологий и норму, во втором случае все изображения были разделены на норму и патологию.

Было установлено, что максимального значения точность достигает к 15 эпохе и дальнейшее обучение не приводит к снижению ошибки обучения.

Вместо анализа метрик точности производилась оценка изменения карт активации классов и вероятности предсказаний нейронной сети специалистом. В процессе обучения количество корректно распознанных примеров росло в каждом варианте обучения, а карта активации классов стала соответствовать определённым областям на изображении. С вероятностью значительно превышающей 50 процентов нейронная сеть научилась предсказывать снимки без патологии и снимки

на которых наблюдалась массивная инфильтрация, отличать, в случае бинарной классификации, снимки с патологиями, в целом, от нормальных. Анализ областей на изображении, которые были ответственны за выбор класса победителя показали, что наиболее значимый вклад в принятие решения об отсутствии патологии вносили области ключицы, подмышки, живота и проксимальной головки плечевой кости. В случае определения инфильтрации, нейронная сеть обращала внимание на лёгочную ткань и левый контур сердца (смотрите рисунок 3.1).

С точки зрения рентгенологии, области подмышек и живота не несут информации о состоянии лёгочной ткани. Исключением служит лишь газ в брюшной полости. Изображения с такой патологией нейронной сети не предъявлялись. Вероятно, такой набор областей интереса был продиктован тем, что пациентов в тяжёлом состоянии чаще снимают в неправильной проекции, лёжа, не отводя руки в стороны, что приводит к попаданию большего количества тканей живота на снимок и суперпозиционному наложению лопаток на область лёгких, изменению пропорций изображения. Область сердца, представляет интерес определения инфильтрации - наблюдается размытие контура сердца. Наиболее важным признаком инфильтрации является снижение прозрачности областей лёгочных полей неоднородного характера. Это признак отражался на карте активации классов, но лишь при массивной инфильтрации. Всё вышеизложенное говорит, о неудовлетворительных результатах обучения нейронной сети resnet50. Данная проблема характерна, как для обучения мультиклассовой классификации, так и при обучении бинарной классификации.




Рис. 3.1 Корректно опознанные изображения, после 15 эпох обучения. А - без патологии в двух вариантах обучения; Б - гидроторакс, вариант с бинарной классификацией; В - полисегментарная пневмония, вариант с мультиклассовой классификацией.

Предварительные результаты эксперимента с VGG19 показали, что эта проблема менее выражена у данной архитектуры. Можно предположить, что такой путь обучения нейронной сети связан непосредственно с архитектурой ResNet и её главной особенностью - пропуску слоёв на начальном этапе для ускорения обучения.

В результате проведения анализа работы нейронной сети был сделан вывод о том, что ResNet50, после 15 эпох обучения в варианте со случайно инициализированными весами показывает неудовлетворительные результаты, связанные с вниманием к косвенным признакам патологии, таким, как положение пациента, при проведении рентгенографии. Кроме того было отмечено, что нейронная сеть склонна больше внимания уделять участкам изображения со значениями пикселей близкими к 255 (белый цвет). Кроме этого, как в случае VGG19, так и в случае ResNet50 результат сильно зависел от угла поворота изображения. В следствии наличия вышеописанных проблем было решено использовать трансферное обучение, отказаться от случайного вращения, акцентировать внимание на обучении

архитектуры VGG19.

3.3 Трансферное обучение с весами, без модификации весов ImageNet

3.3.1 Описание экспериментов

Первый вариант трансферного обучения, который был реализован представлял собой нейронную сеть VGG19 с весами ImageNet. К сети были добавлены два полносвязанных слоя по 2048 нейронов. Число нейронов и полносвязанных слоёв подбиралось эмпирически при тестировании нейронной сети на небольших выборках. Обучались только выходные нейроны, веса предыдущих слоёв не менялись. Таким образом уже выученные на обычных изображениях признаки применялись к рентгеновскому изображению и комбинировались в диагноз на последних слоях. Такая стратегия обучения за счёт небольшого количества изменяемых параметров должна была способствовать обобщению данных и исключить изучение признаков, характерных только для нашей небольшой выборки. Частично, как показывают следующие разделы, подобная стратегия достигла желаемого результата. Переобучение в выборке троичных классификаторов было выражено значительно меньше.

Для всех классификаторов наблюдался рост во всех метриках в течении 30 эпох, как на обучающей так и на валидационной выборке. В валидационной выборке присутствовала достаточно высокая нестабильность. Нестабильность возрастала к последним эпохам. Для сравнения первой представлена кривая обучения Мультиклассификатора по всем 14 классам, с одним из троичных классификаторов. Примеры кривых обучения представлены на рисунке ниже.

График обучения, мультиклассовый классификатор.
1-10 и 20-30 эпохи обучения. Метрика "categorical_accuracy"





График обучения, троичный классификатор (Класс пневмоторакс)
1-10 и 20-30 эпохи обучения. Метрика "categorical_accuracy"






Рис. 3.2 Рост точности мультиклассификатора с фиксированными значениями весов ImageNet и дополнительными полносвязанными слоями и троичного классификатора с той же архитектурой.

Как показано на рисунке выше наблюдается неспособность мультиклассификатора выйти за пределы точности в 20 процентов. Это говорит о недостаточном числе параметров в конечных слоях для обобщения всех 14 классов. Из-за столь низких показателей точности дальнейшее исследование мультиклассового классификатора с фиксированными весами первых слоёв не проводилось. Можно сделать


вывод, что обучение нейронной сети различению небольшого количества классов приводит к большим показателям точности. Было принято решение использовать классификацию по трём классам “Норма”, “Целевая патология”, “Иная патология”. Такая задача относительно проста, а результаты могут быть использованы в ансамбле нейронных сетей или экспертной системе.

Далее представлены кривые обучения AUC и Categorical_Accuracy троичного классификатора, обучающегося распознавать класс Ателектаз. Как мы видим из рисунка ниже кривые увеличиваются одновременно и повторяют форму друг друга. Такое поведение кривых показывает, что точность достигается не за счёт превосходящего класса и метрика Categorical_Accuracy адекватна нашей задаче.



AUC





Accuracy



1-10 Эпохи



10-20 Эпохи



20-30 Эпохи

Рис. 3.3 Кривые обучения, VGG19, троичный классификатор, класс ателлектас.

3.3.2 Анализ метрик точности троичных классификаторов по классам.

Оценивались следующие параметры. Точность - определяет число истинно-положительных результатов по отношению к числу ложно-положительных и истинно-положительных. Она характеризует избирательность сети. Отзыв, характеризует общий процент найденных экземпляров данного класса. F1 мера - показывает взвешенный результат точности и отзыва. Ниже показано, как соотносятся для всех целевых классов параметры точности и отзыва у всех троичных классификаторов.




Рис. 3.4 Все метрики классификации, обучающая выборка. VGG19, 30 эпох обучения, троичные классификаторы.




Рис. 3.5 Все метрики классификации, тестовая выборка. VGG19, 30 эпох обучения, троичные классификаторы.

Как видно из диаграмм выше отзыв преобладает над точностью по всем классам и в тестовой и в обучающей выборке. Такое соотношение говорит о том, что троичные классификаторы склонны определять целевую патологию в ущерб классам “иная патология” и “норма”. Вероятно, это связано с используемыми для устранения дисбаланса классов весами классов, полученными автоматически с помощью Sklearn. Не наблюдается, как противопоставления параметров, так и их значимой корреляции. Исключением является класс *Hernia* (грыжа). Его точность значительно снижена по отношению к отзыву.

Далее показано, как меняется точность и отзыв в тестовой и тренировочных выборках.




Рис. 3.6 Точность по всем классам, тестовая и обучающая выборки.VGG19, 30 эпох обучения, троичные классификаторы.




Рис. 3.7 Отзыв по всем классам, тестовая и обучающая выборки.VGG19,

30 эпох обучения, троичные классификаторы.

Наблюдается некоторое снижение обоих параметров на обучающей выборке. Это свидетельствует о небольшом переобучении невысокой склонности троичных классификаторов запоминать тестовые примеры вместо того, что бы попытаться их обобщать.

В классах пневмония и пневмоторакс падение отсутствует. Наиболее выражено эффект определяется в классе Hernia (Грыжа).

3.3.3 Анализ карт активаций классов троичных классификаторов

Вначале показаны несколько примеров классов, в наилучшей степени определяемых троичными классификаторами. Как видно на представленных ниже изображениях неправильно промаркированные, как пневмония снимки распознаются, как норма, при этом анализ карты активации классов инвертированного изображения показывает, что большую роль в принятии этого решения сыграли области соответствующие тканям лёгких. В неинвертированном изображении, кроме тканей лёгких большое значение в принятии решения играют области живота и позвоночника.



Рис. 3.8 Неверно промаркированный, как пневмония пример верно распознанный нейронной сетью, как норма(негатив). VGG19 30 эпох обучения.



Рис. 3.9 Неверно промаркированный, как пневмония пример, верно распознанный нейронной сетью, как норма(позитив). VGG19 30 эпох обучения.

На следующих рисунках показан правильно распознанный, как не относящийся к норме или пневмонии класс (“Другая патология”). На данном изображении действительно присутствует расширение левого желудочка сердца (класс “кардиомегалия”)




Рис. 3.10 Верно промаркированный, как “иная патология” пример (негатив). VGG19 30 эпох обучения.

Далее представлена пневмония, верно распознанная классификатором обучавшимся распознавать пневмонию. Участки

непосредственно связанные с инфильтрацией в негативе отмечаются картой активации классов, хотя больших эффект, всё же, вызывает наличие надписи в правом верхнем углу снимка.




Рис. 3.11 Пневмония верно распознанная соответствующим троичным классификатором (негатив). VGG19 30 эпох обучения

На ещё одном демонстрационном изображении ниже нейронная сеть после 30 эпох обучения верно распознаёт пневмоторакс, карта активации классов, в частности, указывает на участки с признаками поражения (отсутствие лёгочного рисунка, смещения средостения), что можно определить по месту расположения дренажных трубок. Тем не менее, как и на большинстве изображений в позитиве нейронная сеть склонна обращать внимание на область живота.



Рис. 3.12 Верно распознанный соответствующим троичным классификатором пневмоторакс (позитив). VGG19, 30 эпох обучения. VGG19, 30 эпох обучения.



Рис. 3.13 Ложно размеченный, как пневмоторакс снимок верно определяется нейронной сетью. VGG19, 30 эпох обучения.

Хуже всего показал себя класс *Hernia* (грыжа). Примеров этого класса в выборке так мало, что наш генератор, выбирающий для демонстрации случайно небольшое количество снимков не сгенерировал ни одного примера верно распознанной патологии.

Несмотря на хорошие статистические показатели работу не всех троичных классификаторов можно назвать успешной. Особенно это относится к классу *Mass* (объемное образование). Результаты анализа карт классов этой патологии представлены ниже.



Рис. 3.14 Ложно-отрицательное заключение по классу “Mass”. Нейронная сеть игнорирует объёмное образование. VGG19, 30 эпох обучения.



Рис. 3.15 Верное заключение по классу “Mass”. Нейронная сеть обращает внимание на сторонние объекты, средостение и живот полностью игнорируя объёмное образование. VGG19, 30 эпох обучения.

Приведённые выше изображения иллюстрируют общую тенденцию выявленную нами. VGG19 в варианте троичной классификации показывает большую склонность в выделении адекватных с рентгенологической точки зрения признаков. Исключением из этой тенденции оказывается класс Mass “Объёмное образование”. Использование предварительного преобразования “случайная инверсия” не приводит к значительному изменению точности, но позволяет добиться большего соответствия областей обозначенных картами

активации классов, при подачи инвертированного изображения, областям с патологиями, исключая не имеющие диагностической ценности в диагностике лёгких области живота.

3.3.4 Ансамбль троичных классификаторов.

После обучения троичных классификаторов результаты их предсказаний были на всей обучающей выборке были сохранены и на них были обучены несколько нейронных сетей, с целью улучшить точность предсказаний. Этот метод не оправдал себя. Сумарные показатели точности были сравнимы с каждым отдельным классификатором и росли до 40 процентов(смотрите рисунок). Предсказания по каждому отдельному классу были хуже чем у троичных классификаторов. Исключение составил класс *Hernia* (Грыжа).




Рис. 3.16 Результаты обучения ансамбля троичных классификаторов

3.4 Трансферное обучение с изменением весов ImageNet

3.4.1 Описание экспериментов с VGG19

В предыдущем разделе было показано, что полноценное трансферное обучение приводит к значительному ограничению роста точности мультиклассификатора. В следствии этого, было решено использовать трансферное обучение, без заморозки весов. В этом случае классификатор, начиная с уже готовых признаков может их видоизменять в процессе обучения. Мультиклассификаторы учились распознавать каждый класс, включая No Finding (нет патологии).

Обучение происходило в нескольких вариантах:

1. Обычное обучение - изображение не предобрабатывалось.
2. Случайная инверсия - изображение случайно подавалось в инвертированном виде в 50% процентах случаев.
3. Предобработка фурье

На последнем варианте стоит остановиться подробнее. В применении к рентгенологическим изображениям особый интерес вызывают высокие частоты, которм должна соответствовать инфильтрация. Часто отличить инфильтрацию от локального фиброза усиление лёгочного рисунка или интерстициального компонента представляется проблематичным, даже профессиональному рентгенологу. Наше предположени состояло в том, что анализ спектра этого участка мог бы помочь справиться с вышеобозначенной проблемой.







Рис. 3.17 Преобразование фурье рентгенологического изображения, с пневмонией и без неё. Зелёным маркером отмечены области высоких частот более выраженные для изображения с пневмонией.




Поскольку преобразование фурье при применении к изображению порождает двумерный комплексозначный спектр естественным решением тут служило бы использование комплекснозначных нейронов. К сожалению на данный момент эта технология находится в зачаточном состоянии и её использование могло бы внести дополнительные искажения. В следствии этого было принято решение перевести мнимую часть спектра в набор действительных чисел и использовать одну из половин симметричного спектра, для заполнения её значениями половины мнимого спектра. Поскольку значения которые генерировало преобразование фурье выходили далеко за рамки предназначенные для VGG19 оно было нормировано, после чего подавалось сети как простое изображение.

Кривые обучения AUC(1) и Ассигасу(2) мультиклассовых классификаторов




на обычных изображениях(A) и изображениях, подвергшихся преобразованию фурье(B) показаны ниже. Как мы видим из приведённых рисунков в течении обучения наблюдался рост показателей, как в обучающей, так и валидационной выборках, явных признаков переобучения не наблюдалось, но, как и в предыдущих случаях наблюдалась некоторая нестабильность результатов на






A1



B1



A2



B2

валидационной выборке.

Рис. 3.18 Кривые обучения VGG19 AUC и Accuracy (1-30 эпохи)

3.4.2 Анализ метрик точности мультиклассификаторов VGG19 по классам.

Ниже подробно рассмотрены результаты тестирования по классам. В первую на рисунке ниже показано, как соотносятся Точность и Отзыв для мультиклассификаторов использовавших преобразование фурье, инверсию, их сочетание или не использовавших при обучении дополнительную предобработку изображений.




Рис. 3.19 Отзыв и точность, все варианты обучения, VGG19, 30 эпох обучения, обучающая выборка. Оттенками красного обозначены показатели отзыва, оттенками синего точности.

Как и в случае троичных классификаторов, наблюдается преобладание

отзыва над точностью. Исключение составляет класс инфильтрации, в котором их значения сближаются и класс “Без патологии”, в котором отзыв резко снижается а точность повышается. Это говорит о преобладании за счёт весов вероятности выбора нейронной сетью классов патологии и гипердиагностике. В тестовой выборке эффект практически исчезает




Рис. 3.20 Отзыв и точность, все варианты обучения, тестовая выборка, VGG19, 30 эпох обучения. Оттенками красного обозначены показатели отзыва, оттенками синего точности.

Ниже показано сравнение результатов работы мультиклассовых классификаторов на тестовой и обучающей выборке, в различных вариантах обучения. Как видно из графиков ниже в тестовой выборке точность ниже практически во всех классах, кроме класса No Finding (без патологии). Это говорит о переобучении. Переобучение более выражено, чем в вариантах с троичными классификаторами и трансферным обучением с замороженными слоями, что соответствует известным теоретическим положениям. Инверсия изображения не оказывает решающего значения на показатели точности, но может наблюдаться значительные различия в некоторых классах. В случае сочетания с преобразованием Фурье она оказывает негативный эффект.




Рис. 3.21 Точность, на тестовой и обучающей выборке, обучение с инверсией и без неё VGG19, 30 эпох обучения




Рис. 3.22 Отзыв, на тестовой и обучающей выборке, обучение с инверсией и без неё. VGG19, 30 эпох обучения




Рис. 3.23 Точность, на тестовой и обучающей выборке, обучение с инверсией и

без неё, в сочетании с преобразованием фурье. VGG19, 30 эпох обучения




Рис. 3.24 Отзыв, на тестовой и обучающей выборке, обучение с инверсией и без неё, в сочетании с преобразованием фурье. VGG19, 30 эпох обучения

Для оценки итоговой производительности классификаторов и её сравнения в при обучении на изображениях с различной предобработкой ниже приведены F-меры для всех вариантов обучения на тестовой выборке.




Рис. 3.25 F-мера для всех вариантов обучения (тестовая выборка).VGG19, 30 эпох обучения

Как видно из приведённого выше графика немного более низкие показатели имеет нейронная сеть, обучавшаяся на инвертированных изображениях подвергавшихся преобразованию фурье. Остальные классификаторы обладают схожими результатами отличающимися от класса к классу.

3.4. 3 Анализ карт активаций классов мультиклассификаторов VGG19

Для классификаторов использовавших преобразование фурье в качестве предобработки изображений анализ карт активаций классов показал реакцию на области соответствующие различным частотам. Интерпритация этого результата затруднена.

Для мультиклассификаторов использовавших инверсию, как и в случае с троичными классификаторами результаты были несколько лучше (рис). На рисунке ниже показана карта активации класса “Ателектаз”. Нейронная сеть интерпритирует изображение неверно, но указывает корректную область поражения. С рентгенологической точки зрения, патологии ателектаз и гидроторакс имеют определённое сходство. Ателлектас характеризуется затемнением треугольной формы, гидроторакс затемнением с горизонтальным уровнем. При ателектазе может наблюдаться смещения средостения, что так же отражено на рисунке ниже.



Рис. 3.26 Карта активации класса “Ателектаз” (негатив), мультиклассификатор VGG19, 30 эпох обучения.

Наиболее явным отличием выявленным у мультиклассификаторов, в отличие от троичных классификаторов стало адекватное выделение объёмных образований. На рисунках ниже мультиклассификаторы корректно обозначили область патологии даже на нестандартном изображении - изображение представляет собой фотографию снимка ребёнка небольшого размера.



Рис. 3.27 Карта активации класса Mass (“Объёмное образование”), мультиклассификатор VGG19, 30 эпох обучения.




Рис. 3.28 Карта активации класса Mass (“Объёмное образование”), мультиклассификатор VGG19, 30 эпох обучения.

Тем не менее, такая картина наблюдается не во всех случаях. Сохранилась реакция на признаки не несущие диагностического значения. Так, на рисунках ниже представлена карта активации класса Pleural_Thickening (“Плевральные наложения”) Наибольшее значение в выборе, осуществлённой нейронной сетью сыграли области на периферии лёгочной ткани.



Рис. 3.29 Карта активации класса Pleural_Thickening (“плевральные наслоения”), мультиклассификатор VGG19, 30 эпох обучения.

В целом, карты активации классов в наибольшей степени соответствующие рентгенологическим признакам демонстрировались, при выявлении пневмонии и инфильтрации.



Рис. 3.30 Карта активации класса Infiltration (“инфильтрация”), мультиклассификатор VGG19, 30 эпох обучения.

3.3.4 Описание экспериментов с мультиклассификаторами ResNet50

Учитывая улучшение результатов, при использовании трансферного обучения в сочетании с изменяемыми весами у мультиклассификаторов VGG19 было принято решение провести исследования мультиклассификаторов на основе ResNet50 по той же схеме. Обучение проводилось в двух вариантах. В первом случае для предобработки изображения использовалась стандартная функция ResNet. Во втором случае, изображение предварительно переводилось в формат тепловой карты. Нейронные сети VGG19 и ResNet, как уже сказано выше, предназначены для классификации изображений в формате RGB, в то время, как рентгенологические изображения, фактически являются изображениями в градациях серого, что может, в теории, ухудшать результаты различения изображений.

3.3.5 Анализ метрик точности по классам мультиклассификаторов на основе ResNet50

Полученные при тестировании **ResNet50** результаты представлены на рисунках ниже.




Рис. 3.31 Отзыв и точность на тестовой и обучающей выборке, ResNet50 после

30 эпох обучения.




Рис. 3.32 Отзыв и точность на тестовой и обучающей выборке, ResNet50 после 30 эпох обучения. Изображение предварительно превращались в тепловые карты.

Как мы видим из рисунков выше, как и в случае с VGG19 наблюдается падение точности на тестовой выборке. В отличие от VGG19 нейронная сеть ResNet50 обладает меньшей дистанцией между Отзывом и Точностью, при обучении, особенно, в варианте с простым обучением.

Для оценки совокупной производительности использовалась F-мера. Как видно из рисунка ниже ResNet50 в обычном варианте обучения демонстрирует худшие результаты, чем VGG19, но ResNet обученная на предварительно преобразованных в тепловую карту изображениях превосходит VGG19 в большинстве классов. VGG19 использовавшая преобразование фурье по

отношению к обучающим изображениям превосходит остальные варианты обучения в классах “Инфильтрация”, “Без патологии”, “Узелковые образования”, “Объёмные образования”.




Рис. 3.33 F-мера на тестовой выборке, ResNet50 во всех вариантах обучения и VGG19, без инверсии и с обработкой с помощью преобразования фурье после 30 эпох обучения.

3.3.6 Анализ карт активаций классов классификаторов на основе ResNet50

Анализ карт активаций классов во всех вариантах обучения сетей ResNet показал результаты схожие с обучением со случайными начальными весами этого же типа сетей. Признаки выделяемые ResNet мало соответствовали патологиям с рентгенологической точки зрения.

Обсуждение результатов.

В результате проведённых экспериментов в соответствии с поставленными задачами было проведено сравнение двух типов архитектур, 4 архитектур, одного ансамбля нейронных сетей. Был оценен эффект трёх различных способов предобработки изображений на параметры классификации и выделяемые на изображениях признаки. Обученные классификаторы уступают по точности, отзыву и F-мере классификаторам из опубликованных на данный момент работ, в которых использовался DenseNet121, но близки по точности к результатам классификаторов основанных на архитектуре VGG

Исходя из полученных нами результатов можно сделать ряд выводов.

Нейронные сети при обучения классификации рентгенологических изображений склонны определять незначимые или не поддающиеся интерпритации человеком признаки. Этот эффект может быть по разному выражен в зависимости от архитектуры нейронной сети. В наших экспериментах эта тенденция отчётливо наблюдалась у архитектуры ResNet и была в меньшей степени выражена у архитектуры VGG19. Предварительное преобразование рентгенологического изображения, такое, как случайная инверсия способна уменьшать данный эффект и способствовать выделению нейронной сетью более адекватных с клинической точки зрения признаков. Было установлено, что более высокие показатели классификации не всегда коррелируют с выделением адекватных с медицинской точки зрения признаков.

Способность нейронных сетей различать изображения при анализе его в частотной области, в среднем, не уступает, а в некоторых случаях превосходит способность нейронных сетей различать изображения представленные в обычном формате. Поскольку результаты такого анализа варьировались от класса к классу, это открывает возможность для дальнейших экспериментов в данной области.

Наиболее эффективным с точки повышения F-меры предварительными преобразованием рентгенологического изображения является его представление

в виде тепловой карты.

Обучение нейронных сетей классификации единичной патологии показывает значимый прирост в точности, но объединение таких нейронных сетей в ансамбль его использование не показало значимых положительных результатов.

Были показаны систематические искажения, присутствующие в DataSet “National Institutes of Health Chest X-Ray Dataset”, такие как: отличия в положении пациентов и масштабе изображения, а следовательно и попадании области брюшной полости на снимок у пациентов с патологией; причисление к классу патологии контрольных снимков пациентов не имеющих выраженных рентгенологических синдромов, попадание сторонних объектов, таких как инкубационные трубки и датчики состояния на снимок. Это обстоятельство, может способствовать неправильному обучению систем автоматического анализа рентгенологических изображений.

ГЛАВА 4. Финансовый менеджмент, ресурсоэффективность и ресурсосбережение

4.1 Предпроектный анализ

4.1.1 Потенциальные потребители результатов исследования

Целью проекта является разработка системы автоматического анализа рентгенологических изображений. Данная система может, потенциально, использоваться в качестве замены или системы помощи врачу рентгенологу в бюджетных или коммерческих ЛПУ, в качестве сервисов типа “второе мнение” непосредственно пациентами, в качестве системы массовой оценки количества ошибок рентген диагностики государственными надзорными органами.

Сегментировать рынок услуг можно по степени потребности использования возможностей системы. Результат сегментирования представлены на таблице 4.1

Таблица 4.1. Карта сегментирования рынка

| | | Вид | | |
|-----------------|---------|--|---|--|
| | | Замена или помощь врачу-рентгенологу . | Анализ качества работы врачей-рентгенологов | Предоставление услуг “второе мнение” пациентам |
| Размер компании | Крупные | | | |
| | Средние | | | |
| | Мелкие | | | |

| | | | | | |
|--|-------------------------|--|-----------------|--|--------------------------------------|
| | Государственные клиники | | Частные клиники | | Непосредственный потребитель-пациент |
|--|-------------------------|--|-----------------|--|--------------------------------------|

4.1.2 Анализ конкурентных решений

На данный момент ни одна из подобных разработок не была представлена на рынке. На данный момент отсутствует нормативная база использования систем искусственный интеллект в рентген диагностике, без которой невозможно оценить юридические издержки, в случае ошибок системы, приводящих к смерти или инвалидизации пациента.

4.1.3 SWOT-анализ

SWOT-анализ применяют для исследования внешней и внутренней среды проекта. Матрица составляется на основе анализа рынка и конкурентных технических решений, и показывает сильные и слабые стороны проекта, возможности и угрозы для разработки. Первый этап заключается в описании сильных и слабых сторон проекта, в выявлении возможностей и угроз для реализации проекта, которые проявились или могут появиться в его внешней среде. Матрица SWOT представлена в таблице 4.2

Таблица 4.2 – SWOT-анализ

| | Сильные стороны | Слабые стороны |
|--|--|--|
| | Си1. Большое число способов применения обученной модели. | Сл1. Большое число ошибок системы на данный момент |
| | Си2. Высокая скорость работы системы по сравнению с врачом-человеком | Сл2. Отсутствие нормативно правовой базы использования медицинских ИИ в России и мире. |
| | Си3. Доработка системы осуществляется путём замены новой нейросетевой моделью | Сл3. Быстрорастущая ресурсоёмкость модернизации системы |
| Возможности | | |
| В1. Работа с непосредственным потребителем пациентом на рынке услуг “второе мнение”, со сниженной ответственностью | В1Си1. Адаптация модели под эту задачу не представляет проблем. В1Си2 Системы способна обслуживать большое количество потребителей даже с невысокой мощностью серверной части. В1Си3. Апгрейд сервиса производится без значительных затрат времени и денег | В1Сл1 Система может оказаться бесполезной на начальном этапе В1Сл2 Возможны судебные иски со стороны пациентов В1Сл3 Ресурсы, требуемые для модернизации могут оказаться слишком велики. |

| | | |
|--|--|--|
| В2. Возможность работы на Минздрав РФ в сфере статистического анализа качества работы врачей рентгенологов. | В2Си1. Адаптация модели под эту задачу требует - задача невысокой сложности В2Си2 Системы способна проверять большое количество рентгенологических изображений В2Си3. Апгрейд сервиса производится без значительных затрат времени и денег | Сл2 Подобное предложение может быть отклонено по формальным причинам |
| Угрозы | | |
| У1. Систематическая ошибка распознавания патологии на некоторых рентгенологических изображениях | У1Си1 Любая ошибка модели будет проявляться во всех реализациях системы. С другой стороны её обнаружение и разработка новой модели могут способствовать быстрому исправлению во всех реализациях | У1Сл1 Недостаточная точность системы, на данный момент, делает такой сценарий вероятным. У1Сл2 Правовая ответственность может быть значительной |
| У2. Регулирующие органы могут не одобрить использования систем ИИ для анализа рентгенологических изображений | У2Си3. Есть возможность найти применения в научной сфере и в сфере статистического анализа ЛПУ, требования к которым значительно ниже или могут отсутствовать вовсе | У2Сл1 Для текущей конкретной реализации системы такой сценарий очень вероятен для клинического применения. У2Сл2 Сроки, в которые практическое использования систем подобного рода может быть развёрнуто обладают высокой неопределённостью У3Сл3 Достижение точности работы необходимое для одобрения регулирующими органами может потребовать очень высоких финансовых затрат. |

В рамках SWOT анализа были рассмотрены по три слабых и сильных сторон проекта, а также 2 возможности и угрозы.

Второй этап состоит в выявлении соответствия сильных и слабых сторон научно-исследовательского проекта внешним условиям окружающей среды. Это соответствие или несоответствие должны помочь выявить степень необходимости проведения стратегических изменений.

Соотношения параметров представлены в таблице 4.3.

Таблица 4.3 – Интерактивная матрица проекта

| Сильные стороны проекта | | | | |
|-------------------------|----|-----|-----|-----|
| Возможности | | Си1 | Си2 | Си3 |
| | B1 | + | + | + |
| | B2 | + | + | + |
| Слабые стороны проекта | | | | |
| Возможности | | Сл1 | Сл2 | Сл3 |
| | B1 | + | + | + |
| | B2 | | + | |
| Сильные стороны проекта | | | | |
| Угрозы | | Си1 | Си2 | Си3 |
| | У1 | + | | |
| | У2 | | | + |
| Слабые стороны проекта | | | | |
| Угрозы | | Сл1 | Сл2 | Сл3 |
| | У1 | + | + | |
| | У2 | + | + | + |

Таким образом, самыми большими преимуществами оказываются большое число способов применения системы и возможность быстрого апгрейда всех конкретных реализаций путём замены нейросетевой модели новым лучшим вариантом. Наиболее слабая сторону проекта - отсутствие нормативно правовой базы использования медицинского искусственного интеллекта на данный момент.

4.1.4 Оценка готовности проекта к коммерциализации

На какой бы стадии жизненного цикла не находилась научная разработка полезно оценить степень ее готовности к коммерциализации и выяснить уровень собственных знаний для ее проведения (или завершения). Для этого заполним форму в таблице 6.4, содержащую показатели степени проработанности проекта с позиции коммерциализации и компетенциям разработчика научного проекта.

Таблица 4.4 Оценка степени готовности проекта к коммерциализации

| № п/п | Наименование | Ком- мерция | Компе- тенции |
|----------|--|----------------|------------------|
| 1 | Определен имеющийся научно-технический задел | 3 | 3 |
| 2 | Определены перспективные направления коммерциализации научно-технического задела | 5 | 3 |
| 3 | Определены отрасли и технологии для предложения | 3 | 3 |
| 4 | Определена форма для представления на рынок | 2 | 2 |
| 5 | Определены авторы и осуществлена охрана их прав | 1 | 1 |

| | | | |
|----|---|----|----|
| 6 | Оценена стоимость интеллектуальной собственности | 1 | 1 |
| 7 | Проведены маркетинговые исследования рынков сбыта | 1 | 1 |
| 8 | Разработан бизнес-план коммерциализации разработки | 1 | 1 |
| 9 | Определены пути продвижения разработки на рынок | 2 | 2 |
| 10 | Разработана стратегия (форма) реализации разработки | 3 | 3 |
| 11 | Проработаны вопросы международного сотрудничества и выхода на зарубежный рынок | 1 | 1 |
| 12 | Проработаны вопросы использования услуг инфраструктуры поддержки, получения льгот | 1 | 1 |
| 13 | Проработаны вопросы финансирования коммерциализации научной разработки | 1 | 4 |
| 14 | Имеется команда для коммерциализации разработки | 1 | 1 |
| 15 | Проработан механизм реализации научного проекта | 4 | 5 |
| | ИТОГО БАЛЛОВ | 30 | 32 |

Итоговые значения проработанности научного проекта 30 и знания у разработчика 32, что говорит о том, что некоторые аспекты проекта практически не были проработаны. Так как, работа носит преимущественно научный характер, это приемлемо.

4.1.5 Цели и результаты проекта

Перед определением целей необходимо перечислить заинтересованные стороны проекта. Информация по заинтересованным сторонам представлена в таблице 4.5:

Таблица 4.5. Заинтересованные стороны проекта

| Заинтересованные стороны | Ожидания |
|-------------------------------|---|
| Пользователь | Надёжность диагноза |
| Компания пользователя | Скорость работы и простота обслуживания |
| Разработчик | Получение прибыли |
| Научный руководитель, магистр | Выполненная выпускная квалификационная работа |

Цели и результат проекта представлены в таблице 4.6.

Таблица 4.6 Цели и результат проекта

| | |
|---------------------------------|---|
| Цели проекта | <ul style="list-style-type: none">Изучить теоретические подходы к распознаванию образовВыбрать средства разработкиОбучить и сравнить различные нейросетевые моделиОсуществить интеграцию нейронной сети и веб-интерфейса |
| Ожидаемые результаты | <ul style="list-style-type: none">Найдена наилучшая архитектура нейронной сети для поставленной задачиСдана выпускная квалификационная работа |
| Критерии приёмки | <ul style="list-style-type: none">Успешное тестирование функционала в соответствии с функциональным требованием |
| Требования к результату проекта | <ul style="list-style-type: none">Получены данные о точности работы системы |

4.2 Планирование управления научно-техническим проектом

4.7.1 План проекта

Диаграмма Ганта – это тип столбчатых диаграмм (гистограмм), который используется для иллюстрации календарного плана проекта, на котором работы по теме представляются протяженными во времени отрезками, характеризующимися датами начала и окончания выполнения данных работ.

График строится в виде таблицы с разбивкой по декадам (10 дней) за период времени выполнения научного проекта. При этом работы на графике следует выделить различной штриховкой в зависимости от исполнителей, ответственных за ту или иную работу.

Таблица 4.7. Календарный план-график проведения НИОКР по теме

| Код | Вид | Исп | Тк, кал, дн. | Продолжительность | | | | | | | | | | | | | | |
|--------|--|------|--------------|-------------------|---|---|-------|---|---|------|---|---|------|---|---|-----|---|---|
| | | | | Янв. | | | Февр. | | | Март | | | Апр. | | | Май | | |
| | | | | 1 | 2 | 3 | 1 | 2 | 3 | 1 | 2 | 3 | 1 | 2 | 3 | 1 | 2 | 3 |
| 1 | Выбор направления исследования | Р, И | 4/10 | | | | | | | | | | | | | | | |
| | | | | | | | | | | | | | | | | | | |
| 2 | Описание требований | И | 10 | | | | | | | | | | | | | | | |
| 4 | Составление технического задания | И | 10 | | | | | | | | | | | | | | | |
| 5 | Изучение литературы | И | 20 | | | | | | | | | | | | | | | |
| 6 | Обучение и тестирование различных архитектур нейронных сетей | И | 60 | | | | | | | | | | | | | | | |
| 7 | Разработка веб-интерфейса | И | 20 | | | | | | | | | | | | | | | |
| 8 | Интеграция модели и веб-интерфейса | И | 10 | | | | | | | | | | | | | | | |
| 1 5 | Проверка работы | Р | 4/10 | | | | | | | | | | | | | | | |

■ – Руководитель(Р)

■ – Инженер (С)

4.2.2 Бюджет научного исследования

При планировании бюджета научного исследования должно быть обеспечено полное и достоверное отражение всех видов планируемых расходов, необходимых для его выполнения. В процессе формирования бюджета, планируемые затраты группируются по статьям, представленным в таблице.

4.2.3 Специальное оборудование для научных работ

В данную статью включают все затраты, связанные с приобретением специального оборудования (приборов, контрольно-измерительной аппаратуры, стендов, устройств и механизмов), необходимого для проведения работ по конкретной теме. Определение стоимости спецоборудования производится по действующим прейскурантам, а в ряде случаев по договорной цене.

Для разработки нынешней системы требуется обычное оборудование в виде персонального компьютера и купленных серверов на время жизненного цикла программного продукта. Среда и средство разработки, программный софт и другие комплектующие, нужные для разработки, распространяются бесплатно и не требуют дополнительных затрат (таблица 4.8).

Таблица 4.8 – Расчет затрат на «Спецоборудование для научных работ»

| № | Наименование оборудования | Кол-во | Цена, руб. | Стоимость, руб. |
|-------|------------------------------------|--------|------------|-----------------|
| 1. | Персональный компьютер | 1 | 60 000 | 60 000 |
| 2. | Среда разработки JetBrains PyCharm | 1 | - | - |
| Итого | | | | 60 000 |

4.2.4 Основная заработная плата

В настоящую статью включается основная заработная плата научных и инженерно-технических работников, рабочих макетных мастерских и опытных производств, непосредственно участвующих в выполнении работ по данной теме.

Должность руководителя – доцент, к.т.н. – 35 111,5 рублей в месяц

Должность инженера – студент – 21760 рублей в месяц

Расчет основной заработной платы сводится в таблице 4.9.

Таблица 4.9 – Расчет основной заработной платы

| № п / п | Наименование этапов | Исп | Трудоемкост, чел.-дн. | Зарплата, чел.-дн., руб | Всего руб. |
|---------|---------------------|-----|-----------------------|-------------------------|------------|
| 1 | | Р | 8 | 35111,5 | 35111,5 |
| 2 | | С | 150 | 21760 | |

$$C_{\text{зп}} = Z_{\text{осн}} + Z_{\text{доп}},$$

где $Z_{\text{осн}}$ – основная заработная плата;

$Z_{\text{доп}}$ – дополнительная заработная плата.

Основная заработная плата $Z_{\text{осн}}$ руководителя рассчитывается по следующей формуле:

$$Z_{\text{м}} = Z_{\text{дн}} \cdot T_{\text{раб}}$$

где $T_{\text{раб}}$ – продолжительность работ, выполняемых научно-техническим работником, рабочие дни. (таблица 14);

$Z_{\text{дн}}$ – среднедневная заработная плата работника, руб.

Значит, для руководителя:

$$Z_{\text{м}} = 35111 \cdot 1,3 = 45644 \text{ рублей}$$

Среднедневная заработная плата рассчитывается по формуле:

$$Z_{\text{дн}} = (Z_{\text{м}} \cdot M) / F_{\text{д}}$$

где $Z_{\text{м}}$ – месячный должностной оклад работника, руб

M – количество месяцев работы без отпуска в течение года:

при отпуске в 45 раб. дней $M=10,4$ месяца, 6-дневная неделя;

F_d – действительный годовой фонд рабочего времени научно-технического персонала (в рабочих днях) (таблица 14). Тогда,

Для руководителя:

$$З_{дн} = \frac{45644 * 10,4}{254} = 1\,869 \text{ рублей}$$

Для дипломника:

$$З_{дн} = \frac{21760 * 11,2}{217} = 1123 \text{ рублей}$$

Баланс рабочего времени представлен в таблице 4.10

Таблица 4.10 – Баланс рабочего времени

| Показатели рабочего времени | Руководитель | Инженер |
|--|--------------|---------|
| Календарное число дней | 365 | 365 |
| Количество нерабочих дней | | |
| - выходные дни | 52 | 82 |
| - праздничные дни | 11 | 14 |
| Потери рабочего времени | | |
| - отпуск | 56 | 24 |
| - невыходы по болезни | – | – |
| Действительный годовой фонд рабочего времени | 254 | 217 |

Таблица 4.11 – Результаты расчета основной заработной платы

| Исполнители | $З_б$, руб. | k_p | $З_м$, руб | $З_{дн}$, руб. | T_p , дн. | $З_{осн}$, руб. |
|-----------------------------|--------------|-------|-------------|-----------------|-------------|------------------|
| Руководитель | 35 111,5 | 1.3 | 45644 | 1869 | 4 | 7476 |
| Инженер | 21760 | 1.3 | 28288 | 1123 | 150 | 168450 |
| Итого по статье $З_{осн}$: | | | 175926 | | | |

4.2.5 Дополнительная заработная плата научно-производственного персонала

Дополнительная заработная плата включает оплату за непроработанное время (очередной и учебный отпуск, выполнение государственных обязанностей, выплата вознаграждений за выслугу лет и т.п.) и рассчитывается исходя из 10-15% от основной заработной платы, работников, непосредственно участвующих в выполнении темы:

$$З_{\text{доп}} = k_{\text{доп}} * З_{\text{осн}}$$

где $З_{\text{доп}}$ – дополнительная заработная плата, руб.;

$k_{\text{доп}}$ – коэффициент дополнительной зарплаты ($k_{\text{доп}}=0,1$);

$З_{\text{осн}}$ – основная заработная плата, руб.

Для руководителя:

$$З_{\text{доп}} = 7476 * 0,1 = 747 \text{ рублей}$$

В таблице 4.12 приведен расчёт основной и дополнительной заработной платы.

Таблица 4.12 – Заработная плата исполнителей ВКР, руб

| Заработная плата | Руководитель | Инженер |
|-------------------------|--------------|---------|
| Основная зарплата | 7476 | 168450 |
| Дополнительная зарплата | 747 | 16.845 |
| Зарплата исполнителя | 8224 | 185295 |
| Итого | 193519 | |

4.2.6 Отчисления на социальные нужды

Статья включает в себя отчисления во внебюджетные фонды.

$$C_{\text{внеб}} = k_{\text{внеб}} \cdot (Z_{\text{осн}} + Z_{\text{доп}})$$

где $k_{\text{внеб}}$ – коэффициент отчислений на уплату во внебюджетные фонды (пенсионный фонд, фонд обязательного медицинского страхования и пр.). Равен 0.3

Для руководителя - 2467 руб.

Для инженера - 55560 руб.

Итого 58000 рублей

4.2.7 Накладные расходы

В эту статью относятся расходы по содержанию, эксплуатации и ремонту оборудования, производственного инструмента и инвентаря, зданий, сооружений и др. В расчетах эти расходы принимаются в размере 70 - 90 % от суммы основной заработной платы научно-производственного персонала данной научно-технической организации. Накладные расходы составляют 16% от суммы основной и дополнительной заработной платы, работников, непосредственно участвующих в выполнение темы.

Расчет накладных расходов ведется по следующей формуле:

$$C_{\text{накл}} = k_{\text{накл}} * (Z_{\text{осн}} + Z_{\text{доп}})$$

где $k_{\text{накл}}$ – коэффициент накладных расходов.

$$C_{\text{накл}} = 31\,000 \text{ руб.}$$

4.2.8 Формирование бюджета затрат научно-исследовательского проекта

Рассчитанная величина затрат научно-исследовательской работы является основой для формирования бюджета затрат проекта, который при формировании договора с заказчиком защищается научной организацией в качестве нижнего предела затрат на разработку научно-технической продукции.

Таблица 4.13 – Бюджет затрат НТИ

| Сырье | Оборудование | Осн зп | Доп зп | Накл рас | Отчисления на социальные нужды | Итого |
|-------|--------------|--------|--------|----------|--------------------------------|---------------|
| | 60 000 | 175926 | 17592 | 31 000 | 58 000 | 342518 |

В результате было получено, что бюджет на разработку НТИ составит **342518** руб.

4.3 Оценка научного уровня

Важнейшим результатом реализации проекта является его научно-технический уровень, который характеризует, в какой мере выполнены работы и обеспечивается ли научно-технический прогресс в данной области.

На основе оценок новизны результатов, их ценности, масштабам реализации определяется показатель научно-технического уровня по формуле:

$$H_m = \sum_{i=1}^n K_i \cdot P_i$$

Где K_i – весовой коэффициент i -го признака научно-технического эффекта;

P_i – количественная оценка i -го признака научно-технического уровня работы.

По каждому из факторов экспертным путем при помощи нижеприведенных таблиц устанавливаются численные значения коэффициента значимости, и проставляется балльная оценка.

Таблица 4.14– Признаки научно-технического эффекта

| Признак научно-технического эффекта НИР (i) | Примерное значение весового коэффициента (K_i) |
|---|--|
| 1.Уровень новизны | 0,6 |
| 2.Теоретический уровень | 0,4 |
| 3. Возможность реализации | 0,2 |

Таблица 4.15 – Количественная оценка уровня новизны НИР

| Уровень новизны разработки | Характеристика уровня новизны | Баллы |
|----------------------------|---|-------|
| Принципиальн о новая | Результаты исследований открывают новое направление в данной области науки и техники. | 8-10 |

| | | |
|----------------------|---|-----|
| Новая | По-новому или впервые объяснены известные факты, закономерности. | 5-7 |
| Относительно новая | Результаты исследований систематизируют и обобщают имеющиеся сведения, определяют пути дальнейших исследований. | 2-4 |
| Традиционная работа | Работа выполнена по традиционной методике, результаты которой носят информационный характер. | 1 |
| Не обладает новизной | Получен результат, который был ранее известен | 0 |

таблица 4.16 – Количественная оценка теоретического уровня НИР

| Теоретический уровень полученных результатов | Баллы |
|---|-------|
| 1. Установка закона, разработка новой теории | 10 |
| 2. Глубокая разработка проблемы, многоспектральный анализ, взаимодействия между факторами с наличием объяснений | 8 |
| 3. Разработка способа (алгоритм, программа мероприятий, устройство, вещество и т.п.) | 6 |
| 4. Элементарный анализ связей между фактами с наличием гипотезы, симплексного прогноза, классификации, объясняющей версии или практических рекомендаций частного характера. | 2 |
| 5. Описание отдельных элементарных факторов (вещей, свойств и отношений); изложение опыта, результатов измерений. | 0,5 |

Возможность реализации научных результатов представлена в таблице ниже:

Таблица 4.17 – Возможность реализации научных результатов

| Время реализации | Баллы |
|--------------------------------|-------|
| В течении первых лет | 10 |
| От 5 до 10 лет | 4 |
| Более 10 лет | 2 |
| Масштабы реализации | Баллы |
| Одно или несколько предприятий | 2 |
| Отрасль (министерство) | 4 |
| Народное хозяйство | 10 |

По результатам проведения оценки НИР была составлена сводная таблица оценки научно-технического уровня, на основе которой сделан вывод об ожидаемой эффективности выполняемой НИР.

Таблица 4.18 – Количественная оценка признаков НИР

| Признак научно-технического эффекта НИР | Характеристика признака НИР | K_i | Π_i |
|---|---|-------|---------|
| 1. Уровень новизны | Новая | 0,6 | 6 |
| 2. Теоретический уровень | Разработка способа (алгоритм, программа мероприятий, устройство, вещество и т.п.) | 0,4 | 4 |
| 3. Возможность реализации | От 5 до 10 лет, отрасль | 0,2 | 10 |

Расчет НТУ и его оценка:

$$\text{НТУ} = 0,6 \cdot 6 + 0,4 \cdot 6 + 0,2 \cdot 12 = 7,2$$

Уровень научно-технического эффекта определим по таблице:

Таблица 4.19 – Оценка уровня НТЭ

| Уровень НТЭ | Коэффициент НТЭ |
|----------------------|-----------------|
| Низкий | 1-4 |
| Средний | 5-7 |
| Сравнительно высокий | 8-10 |
| Высокий | 11-14 |

Из таблицы видно, что разработанная система имеет средний уровень научно-технический эффект.

Выводы по разделу.

В ходе данной работе были рассмотрены потенциальные потребители результатов исследования, был сформирован SWOT-анализ, в котором были описаны сильные и слабые стороны проекта, в выявлении возможностей и угроз для реализации проекта, для выявления соответствия и несоответствия была составлена интерактивная матрица проекта.

Проведена оценка готовности проекта к коммерциализации, которая показала, что перспективность разработки низкая.

В рамках процессов инициации определены внутренние и внешние заинтересованные стороны проекта с их ожиданиями от проекта, цели и результат проекта.

План проекта представлен на диаграмме Ганта, из которого видно какой исполнитель (магистр или руководитель) какой вид работ осуществлял и в течении какого количества дней.

Была рассчитан бюджет проекта, который составил **342518** .

Была оценена научная эффективность проекта , она является средней.

ГЛАВА 5. СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ

Целью работы является создание автоматической системы анализа рентгенологических изображений. Основная работа с системой и работа по её созданию производится с использованием персонального компьютера в жилом помещении.

Работа проводилась в жилом помещении общежития ТПУ Усова 15б. Характеристика помещения, где проводились работы по ВКР: ширина комнаты составляет $b = 4.5$ м, длина $a = 6$ м, высота $H = 2,8$ м. Площадь помещения будет составлять $S = ab = 27$ м², объем $V = abh = 81.4$ м³; присутствует окно, через которое может производится вентиляция помещения, принудительная вентиляция отсутствует; в зимнее время помещение отапливается; в помещении используется комбинированное освещение. Схема помещения представлена на рисунке 5.1.




Рис. 5.1 Схема рабочего помещения.

5.1 Правовые аспекты обеспечения безопасности

Исходя из общепризнанных принципов и норм международного права и в соответствии с Конституцией Российской Федерации основными принципами правового регулирования трудовых отношений обеспечение права каждого работника на справедливые условия труда, в том числе на условия труда, отвечающие требованиям безопасности и гигиены, регламентируемых признанными в РФ нормативными правовыми документами, такими как: ГОСТ, СанПиН, СНИПТОИ [35].

Продолжительность рабочего дня не должна превышать 40 часов в неделю. В течение рабочего дня работнику должен быть предоставлен перерыв для отдыха и питания продолжительностью не более двух часов и не менее 30 минут. Всем работникам предоставляются выходные дни [35].

В целях обеспечения прав и свобод человека и гражданина работодатель и его представители должны соблюдать требования ТК РФ по получению и обработке персональных данных. В целях обеспечения защиты персональных данных, хранящихся у работодателя, работники имеют право на: полную информацию об их персональных данных и обработке этих данных; свободный бесплатный доступ к своим персональным данным; доступ к медицинской документации, отражающей состояние их здоровья; требование об исключении или исправлении неверных или неполных персональных данных, а также данных, обработанных с нарушением требований настоящего Кодекса или иного федерального закона [36].

5.2 Эргономические требования к рабочему месту

Место оператора ЭВМ регламентируется следующими нормативными актами: СанПиН 1.2.3685-21, ТК РФ от 30.12.2001 N 197-ФЗ (ред. от 09.03.2021), ТОО Р-45-084-01, ГОСТ 22269-76, ГОСТ Р 50923-96, ГОСТ 12.2.032-78 [35,36,37,38,39,40].

В случаях, когда характер работы требует постоянного взаимодействия с компьютером (работа программиста разработчика) с напряжением внимания и сосредоточенности, при исключении возможности периодического переключения на другие виды трудовой деятельности, не связанные с ПЭВМ, рекомендуется организация перерывов на 10–15 мин. через каждые 45–60 мин. работы. Конструкция рабочей мебели (рабочий стол, кресло, подставка для ног) должна обеспечивать возможность индивидуальной регулировки соответственно росту пользователя и создавать удобную позу для работы. [35,37].

5.3 Производственная безопасность

Для обеспечения безопасности во время эксплуатации и разработки программы, необходимо провести анализ вредных и опасных воздействий на человека, которые могут возникать при разработке или эксплуатации проекта. Производственный фактор является вредным, в том случае если он приводит к заболеванию работника. В случае если его воздействие может привести к травме, то фактор является опасным. Выявленные вредные и опасные факторы приведены ниже.

Вредные факторы:

1. Электромагнитные поля;
2. Электростатические поля;
3. Шум и вибрации;
4. Отклонения показателей микроклимата от нормы в помещении;
5. Недостаточная освещенность рабочей зоны;
6. Психофизиологические факторы (монотонность труда, нервно-

психические перегрузки, перенапряжение зрительных анализаторов).

Опасные факторы:

1. Поражение электрическим током;
2. Короткое замыкание;
3. Статическое электричество.

5.3.1 Вредные производственные факторы

5.3.1.1 Отклонения показателей микроклимата от нормы в помещении

Пониженная или же повышенная температура воздуха рабочей зоны считается вредным производственным фактором и является фактором микроклимата рабочей среды, параметры которого регулируются СанПиН 1.2.3685-21, СанПиН 2.2.4.548-96 [36, 39].

Во время работы с ПЭВМ в производственных помещениях происходит систематическое выделение тепла вычислительной техникой, а также вспомогательными устройствами и средствами освещения. По причине того, что оператор находится поблизости от источников выделения тепла, данный фактор является одним из вредных факторов производственной среды оператора ПЭВМ, а высокая температура воздуха способствует быстрому перегреву организма и повышению утомляемости. Влажность оказывает сильное влияние на терморегуляцию организма. Высокие показатели относительной влажности (более 85 %) затрудняют терморегуляцию, показатели влажности менее 20 % вызывают пересыхание слизистых оболочек человека.

Санитарные нормы устанавливают оптимальные и допустимые значения величин показателей микроклимата рабочих мест для различных категорий работ в теплый и холодный периоды года. Для создания благоприятных условий труда и повышения производительности необходимо поддерживать оптимальные параметры микроклимата производственных помещений. Для этого должны быть предусмотрены следующие средства: центральное отопление, вентиляция (искусственная и естественная), искусственное кондиционирование. Исходя из требований, определённой вышеприведённой нормативной документацией, в жилом помещении, в котором проводилось исследование поддерживалась температура равная 20 –21 °С, при относительной влажности в 55–58%. В зимнее время в помещении предусмотрена система водяного отопления со встроенными нагревательными

элементами и терморегуляторами. Также, в некоторых случаях, целесообразно обеспечить питьевое водоснабжение. В помещениях для работы с ПЭВМ должна производиться ежедневная влажная уборка, а также систематическое проветривание после каждого часа работы [36, 41].

5.3.1.2 Недостаточная освещенность рабочей зоны

Недостаточная освещенность рабочей зоны является вредным производственным фактором, возникающим при работе с ПЭВМ. Причиной недостаточной освещенности являются недостаточность естественного освещения, недостаточность искусственного освещения, пониженная контрастность. Работа с компьютером подразумевает постоянный зрительный контакт с дисплеем ПЭВМ и занимает от 80 % рабочего времени. Недостаточность освещения снижает производительность труда, увеличивает утомляемость и может привести к появлению профессиональных болезней зрения.

Существуют общие требования и рекомендации к организации освещения на рабочем месте. Рабочее помещение должно иметь естественное и искусственное освещение, соответствующее показателям. В качестве источников искусственного освещения должны быть использованы люминесцентные лампы, лампы накаливания – для местного освещения. Искусственное освещение в помещениях для эксплуатации ПЭВМ должно осуществляться системой общего равномерного освещения, а рабочие места следует размещать таким образом, чтобы естественный свет падал преимущественно слева, а дисплеи монитора были ориентированы боковой стороной к световым проемам [42].

Требования к освещению согласно СП 52.13330.2016 [42] приведены в таблице 5.1:

Таблица 5.1 – Требования к освещению на рабочих местах с ПК [42]

| Вид | Требование |
|-------------------------------|----------------|
| Освещенность на рабочем столе | 200-400 лк |
| Освещенность на экране ПК | Не выше 200 лк |

| | |
|---|------------------|
| Блик на экране | Не выше 40 кд/м2 |
| Прямая блеклость источника света | 200 кд/м2 |
| Показатель ослепленности | Не более 20 |
| Показатель дискомфорта | Не более 15 |
| Отношение яркости | |
| Между рабочими поверхностями | 3:1-5:1 |
| Между поверхностями стен и оборудования | 10:1 |
| Коэффициент пульсации | Не более 10% |

Произведём расчёт этого фактора. Из схемы, которая представлена на рисунке 1 видно, что помещение имеет одно дверь и окно. Площадь помещения составляет 27 м².

Первой задачей размещения светильников является определение расчетной высоты подвеса H_D :

$$H_D = H - h_n - h_{\partial},$$

где H – высота помещения, м;

h_n – расстояние светильников от перекрытия, как правило, принимается в пределах 0–1,5 м;

h_{∂} – высота рабочей поверхности над полом, м.

Соблюдение данных мер позволит сохранить зрение работника или избежать пагубного воздействия на глаза. Так как высота потолка данного помещения 2,8, то оптимальное значение размещения 2.1 м. Выбираем лампу дневного света ЛД-40, световой поток которой равен $\Phi_{ЛД} = 2300$ Лм. Выбираем светильники с люминесцентными лампами типа ОДОР-2-40. Этот светильник имеет две лампы мощностью 40 Вт каждая, длина светильника равна 1227 мм, ширина – 265 мм.

На первом этапе определим значение индекса освещенности:

$$i = S/(a+b) \cdot h,$$

где S – площадь помещения; h – расчетная высота подвеса светильника, м; a и b – длина и ширина помещения, м.

В результате проведенных расчетов получаем значение индекса освещенности, равное $i = 1.5$.

Расстояние между соседними светильниками или рядами определяется по формуле:

$$L = \lambda \cdot h = 1,1 \cdot 1,55 = 1,6 \text{ м.}$$

Число рядов светильников в помещении:

$$Nb = b/L$$

Число светильников в ряду:

$$Na = a/L$$

Общее число светильников:

$$N = Na \cdot Nb = 4 \cdot 3 = 12.$$

Учитывая, что в каждом светильнике установлено две лампы, общее число ламп в помещении $N=24$.

Расстояние от крайних светильников или рядов до стены определяется по формуле: $l = L/3$ и равняется 0.53 м

Размещаем светильники в три ряда, тогда световой поток лампы определяется по формуле:

$$\Phi = \frac{E_n \cdot S \cdot K_z \cdot Z}{N \cdot \eta}$$

где E_n – нормируемая минимальная освещенность по СНиП 23-05-95, лк; S – площадь освещаемого помещения, м²; K_z – коэффициент запаса, учитывающий загрязнение светильника (источника света, светотехнической арматуры, стен и

пр., т.е. отражающих поверхностей), наличие в атмосфере цеха дыма, пыли; Z – коэффициент неравномерности освещения, отношение E_{cp}/E_{min} . Для люминесцентных ламп при расчетах берется равным 1,1; N – число ламп в помещении; η – коэффициент использования светового потока [43].

Данное помещение относится к типу помещения со средним выделением пыли, в связи с этим $K_z = 1,5$; состояние потолка – свежепобеленный, поэтому значение коэффициента отражения потолка $\rho_n = 70$; состояние стен – побеленные бетонные стены, поэтому значение коэффициента отражения стен $\rho_c = 50$.

Коэффициент использования светового потока, показывающий какая часть светового потока ламп попадает на рабочую поверхность, для светильников типа ОДОР с люминесцентными лампами при $\rho_n = 70\%$, $\rho_c = 50\%$ и индексе помещения $i = 1,5$ равен $\eta = 0,47$.

Нормируемая минимальная освещенность при использовании ЭВМ и одновременной работе с документами должна быть равна 600лк.

$$\Phi = \frac{E_n \cdot S \cdot K_z \cdot Z}{N \cdot \eta} = 2106 \text{ Лм}$$

Для люминесцентных ламп с мощностью 40 Вт и напряжением сети 220В, стандартный световой поток ЛД равен 2300 Лм.

Таким образом световой поток светильника не выходит за пределы требуемого диапазона, а отклонение не превышает 8%

5.3.1.3 Производственные шумы

Шум – это совокупность звуков, неблагоприятно воздействующих на организм человека и мешающих его работе и отдыху.

Допустимый уровень шума – это уровень, который не вызывает у человека беспокойства и значительных изменений показателей функционального состояния систем и анализаторов, чувствительных к шуму.

Ненормированный показатель шума на рабочих местах оказывает негативное

воздействие на психологическое состояние сотрудника. У работника на поставленной ему задаче понижаются концентрация и сосредоточенность, а увеличивается утомляемость и стресс. Повышенный уровень шума приводит к нарушению слуха или являться помехой для коммуникаций между сотрудниками. Измерение уровня звука и уровней звукового давления производится на расстоянии 50 см от поверхности оборудования и на уровне расположения источника(ков) звука. Уровень шума исправного компьютера находится в пределах 35-50 дБА, что значительно ниже, чем допустимый уровень шума для данного рабочего места, определённый СН 2.2.4/2.1.8.562-96, СН 2.1.8.562-96 [44, 45].

5.3.1.4 Электромагнитные поля

Источниками электромагнитного излучения на данном рабочем месте выступают системные блоки и мониторы включённых компьютеров. Требования при работе с источниками электромагнитных излучений определяются ГОСТ 12.1.006-84 ССБТ. Допустимым считается 8-часовой рабочий день для сотрудника на своем рабочем месте, с предельно допустимым уровнем напряженности электрического поля не более 8 кА/м, уровнем магнитной индукции – 10 мТл. Соблюдение данных норм дает возможность избежать негативного воздействия электромагнитных излучений [46].

Для защиты операторов ПЭВМ от негативного воздействия электромагнитных полей в первую очередь необходимо, чтобы используемая техника удовлетворяла нормам и правилам сертификации. Кроме этого, для уменьшения уровня электромагнитного поля от персонального компьютера рекомендуется подключать к одной розетке не более двух компьютеров, сделать защитное заземление, подключать компьютер к розетке через нейтрализатор электрического поля, использовать мониторы, уровень излучения которых понижен, установить защитные экраны и соблюдать режимы труда и отдыха. К средствам индивидуальной защиты при работе на компьютере относят спектральные компьютерные очки для улучшения качества изображения и защиты от избыточных энергетических потоков видимого света и для

профилактики. Очки уменьшают утомляемость глаз на 25-30%. Их рекомендуется использовать всем операторам при работе больше 2 часов в день, а при нарушении зрения на 2 диоптрии и более – независимо от продолжительности работы [46].

5.3.2 Опасные производственные факторы

5.3.2.1 Опасность поражения электрическим током

Электробезопасность – система организационных и технических мероприятий и средств, обеспечивающих защиту людей от вредного и опасного воздействия электрического тока, электрической дуги, электромагнитного поля и статического электричества. Нормы электробезопасности на рабочем месте и вопросы требований к защите от поражения электрическим током освещены ГОСТ 12.1.038-82. и ГОСТ Р 12.1.019-2017 ССБТ [47,48].

Помещение, где расположено рабочее место оператора ПЭВМ, относится к помещениям без повышенной опасности ввиду отсутствия следующих факторов: сырость, токопроводящая пыль, токопроводящие полы, высокая температура, возможность одновременного прикосновения человека к имеющим соединение с землей металлоконструкциям зданий, технологическим аппаратам, механизмам и металлическим корпусам электрооборудования. С целью защиты от поражения электрическим током, возникающим между корпусом приборов и инструментом при пробое сетевого напряжения на корпус, корпуса приборов и инструментов должны быть заземлены [47,48].

Для оператора ПЭВМ при работе с электрическим оборудованием обязательны следующие меры предосторожности: перед началом работы нужно убедиться, что выключатели и розетка закреплены и не имеют оголённых токоведущих частей. Все работы по устранению неисправностей должен производить квалифицированный персонал; При включенном сетевом напряжении работы на задней панели должны быть запрещены. При производстве монтажных работ необходимо использовать только исправный инструмент, аттестованный службой КИПиА [47,48].

5.4 Экологическая безопасность

В данном разделе рассматривается влияние на окружающую среду деятельности по разработке проекта, а также самого продукта в результате его реализации на производстве. Нормативы экологической безопасности установлены ГОСТ 17.4.3.04-85, ГОСТ Р 53692-2009 [49,50].

Непосредственно программный продукт, разработанный в ходе выполнения магистерской диссертации, не наносит вреда окружающей среде ни на стадиях его разработки, ни на стадиях эксплуатации. В лаборатории не ведется никакого производства, однако, средства, необходимые для его разработки и эксплуатации могут наносить вред окружающей среде.

К отходам, производимым в помещении, можно отнести, в первую очередь, это бумажные отходы – макулатура, пластиковые отходы, неисправные детали персональных компьютеров и других видов ЭВМ. Бумажные отходы рекомендуется накапливать и передавать их в пункты приема макулатуры для дальнейшей переработки. Пластиковые бутылки складывать в специально предназначенные контейнеры [49,50].

Современные ПЭВМ производят практически без использования вредных веществ, опасных для человека и окружающей среды. Исключением являются аккумуляторные батареи компьютеров и мобильных устройств. В аккумуляторах содержатся тяжелые металлы, кислоты и щелочи, которые могут наносить ущерб окружающей среде, попадая в гидросферу и литосферу, если они были неправильно утилизированы.

Для утилизации аккумуляторов необходимо обращаться в специальные организации, специализировано занимающиеся приемом, утилизацией и переработкой аккумуляторных батарей. Люминесцентные лампы, применяющиеся для искусственного освещения рабочих мест, также требуют особой утилизации, т.к. в них присутствует от 10 до 70 мг ртути, которая относится к чрезвычайно -опасным химическим веществам и может стать

причиной отравления живых существ, а также загрязнения атмосферы, гидросферы и литосферы. Сроки службы таких ламп составляют около 5-ти лет, после чего их необходимо сдавать на переработку в специальных пунктах приема. Юридические лица обязаны сдавать лампы на переработку и вести паспорт для данного вида отходов [49,50].

5.5 Безопасность в чрезвычайных ситуациях

В рабочей среде оператора ПЭВМ возможно возникновение следующих чрезвычайных ситуаций техногенного характера: пожары и взрывы в зданиях и на коммуникациях; внезапное обрушение зданий.

Среди возможных стихийных бедствий можно выделить метеорологические (ураганы, ливни, заморозки), гидрологические (наводнения, паводки, подтопления), природные пожары.

Регулирование пожаробезопасности производится ГОСТ 12.1.004-91. Наиболее характерной для объекта, где размещаются рабочие помещения, оборудованные ПЭВМ, чрезвычайной ситуацией является пожар. Помещение для работы операторов ПЭВМ по системе классификации категорий помещений по взрывопожарной и пожарной опасности относится к категории Д. В помещениях с ПЭВМ повышен риск возникновения пожара из-за присутствия множества факторов: наличие большого количества электронных схем, устройств электропитания, устройств кондиционирования воздуха [17].

Все сотрудники организации обязаны быть ознакомлены с инструкцией по пожарной безопасности, пройти инструктаж по технике безопасности и строго соблюдать его. Запрещается использовать электроприборы в условиях, не соответствующих требованиям инструкций изготовителей, или имеющие различного рода неисправности, которые в соответствии с инструкцией по эксплуатации могут привести к пожару, а также использовать электропровода и кабели с поврежденной или потерявшей защитные свойства изоляцией [51].

Перед уходом из служебного помещения требуется провести его осмотр, закрыть окна, убедиться в том, что в помещении отсутствуют источники

возможного возгорания, все электроприборы отключены и выключено освещение [51].

С периодичностью не менее одного раза в три года необходимо проводить замеры сопротивления изоляции токоведущих частей силового и осветительного оборудования. Увеличение устойчивости достигается за счет проведения соответствующих организационно-технических мероприятий, подготовки персонала к работе в ЧС [51].

При обнаружении пожара или признаков горения требуется [51]:

- Прекратить работу;
- Вызвать пожарную охрану;
- Сообщить непосредственному или вышестоящему начальнику;
- Отключить от сети электрооборудование;
- По возможности , принять меры по эвакуации людей и материальных ценностей;
- При общем сигнале опасности покинуть здание согласно «Плану эвакуации людей при пожаре и других ЧС» (рис 5.2);

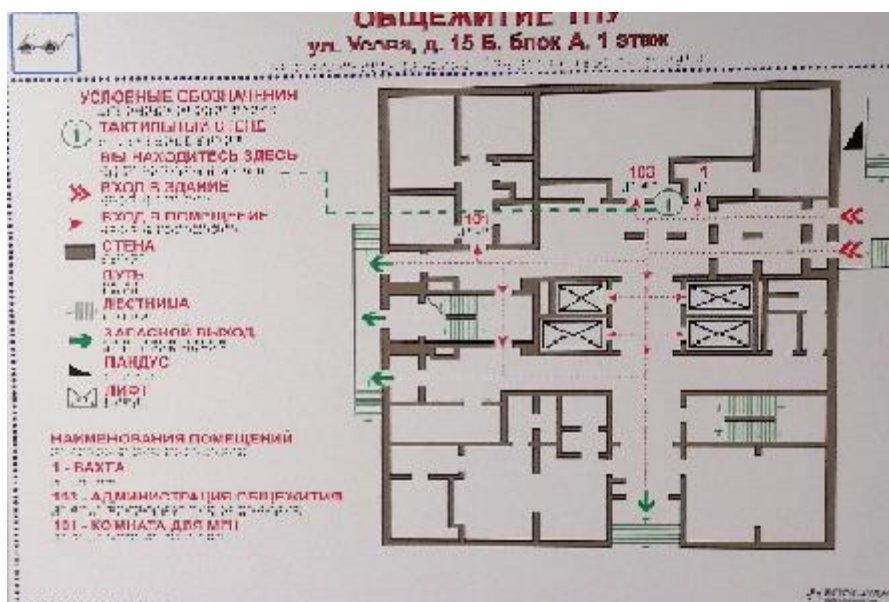


Рисунок 5.2 План эвакуации

Для тушения пожара следует применять ручные углекислотные огнетушители (типа ОУ-2, ОУ-5), находящиеся в помещениях офиса, и пожарный кран внутреннего противопожарного водопровода. Они предназначены для тушения начальных возгораний различных веществ и материалов, за исключением веществ, горение которых происходит без доступа воздуха. Огнетушители должны постоянно содержаться в исправном состоянии и быть готовыми к действию. Категорически запрещается тушить возгорания в помещениях офиса при помощи химических пенных огнетушителей [51].

Выводы по разделу

В данном разделе были рассмотрены основные вопросы соблюдения прав работника на труд, выполнения правил к безопасности труда, промышленной безопасности, экологии и ресурсосбережения.

Установлено, что рабочее место исследователя удовлетворяет требованиям безопасности и гигиены труда во время реализации проекта, а вредное воздействие объекта исследования на окружающую среду не превышает норму.

ЗАКЛЮЧЕНИЕ

Как было показано в нашей работе, на данный момент существует

вероятность значительных систематических ошибок, при обучении нейронных сетей классификации рентгенологических изображений. В первую очередь это связано с используемыми для обучения наборами данных, содержащих систематические искажения. Перед использованием такого искусственного интеллекта в клинической практике эта проблема должна быть решена. Мы видим два пути решения проблемы.

Первый состоит в полностью ручной маркировке, специально подобранных рентгенологических изображений, исключающих не описанное наличие сторонних объектов и сложных противоречивых примеров, подготовленным к такой задаче врачом-рентгенологом. Необходимо дополнительно отмечать положение пациента. Желательно вручную выделить области патологии, для обучения таких архитектур, как U-net. В обязательном порядке должен проводиться контроль нейронных сетей с помощью карт активации классов, даже при высоких показателях точности. Должен производиться подбор архитектуры и способа предобработки изображения максимизирующий результаты как первого, так и второго способа оценки нейронных сетей. Этот путь требует значительных временных и финансовых затрат. Вторым путём является использование обучения без учителя, для предварительной кластеризации рентгенологических изображений, с последующим обучением их с учителем. Этот способ может снизить финансовые и временные затраты.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

4. 2017 IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE 2017). Proceedings of a meeting

held 17-19 July 2017, Philadelphia, Pennsylvania, USA.

5. Y. Bar, I. Diamant, L. Wolf, S. Lieberman, E. Konen, and H. Greenspan, "Chest pathology identification using deep feature selection with nonmedical training," *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, vol. 6, no. 3, pp. 259–263, 2018.
6. H.-C. Shin, K. Roberts, L. Lu, D. Demner-Fushman, J. Yao, and R. M. Summers, "Learning to read chest x-rays: Recurrent neural cascade model for automated image annotation," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 2497–2506.
7. X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, and R. M. Summers, "Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases," in *Computer Vision and Pattern Recognition (CVPR), 2017 IEEE Conference on*. IEEE, 2017, pp. 3462–3471.
8. P. Rajpurkar, J. Irvin, K. Zhu, B. Yang, H. Mehta, T. Duan, D. Ding, A. Bagul, C. Langlotz, K. Shpanskaya et al., "Chexnet: Radiologist level pneumonia detection on chest x-rays with deep learning," *arXiv preprint arXiv:1711.05225*, 2017.
9. C. Yan, J. Yao, R. Li, Z. Xu, and J. Huang, "Weakly supervised deep learning for thoracic disease classification and localization on chest xrays," in *Proceedings of the 2018 ACM International Conference on Bioinformatics, Computational Biology, and Health Informatics*. ACM, 2018, pp. 103–110.
10. G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks." in *CVPR*, vol. 1, no. 2, 2017, p. 3.
11. J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," in *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*. Ieee, 2009, pp. 248–255.
12. Zhicheng Huang, Dongmei Fu* School of Automation and Electrical Engineering, University of Science and Technology Beijing, China "Diagnose Chest Pathology in X-ray Images by Learning Multi-Attention Convolutional Neural Network", in *Proceedings of the IEEE 8th Joint International Information Technology and Artificial Intelligence Conference* 2019.

13. К. Воронцов. Линейные методы классификации и регрессии: метод стохастического градиента // [Электронный ресурс]. – Режим доступа: <http://www.machinelearning.ru/wiki/images/5/53/Voron-ML-Lin-SG.pdf> -дата доступа: 22.05.2021.
14. Mohamed Aly, Survey on Multiclass Classification Methods,. Technical Report, Caltech, USA, 2005.
15. Категориальная кроссэнтропия // [Электронный ресурс]. – Режим доступа: <https://peltarion.com/knowledge-center/documentation/modeling-view/build-an-ai-model/loss-functions/categorical-crossentropy> -дата доступа: 22.05.2021.
16. Multilabel classification // [Электронный ресурс]. - Режим доступа: https://en.wikipedia.org/wiki/Multi-label_classification - дата доступа 19.05.2021
17. Бинарная кроссэнтропия // [Электронный ресурс]. – Режим доступа: <https://towardsdatascience.com/understanding-binary-cross-entropy-log-loss-a-visual-explanation-a3ac6025181a> - дата доступа 14.05.2021
18. Что такое нейронные сети, что они могут, и как написать нейронную сеть на Python? [Электронный ресурс]. Режим доступа: <https://neural-university.ru/neural-networks-basics> - дата доступа 01.01.2021
19. <https://neural-university.ru/neural-networks-basics> (Дата обращения: 25.04.2020).
20. Convolutional Neural Networks (LeNet) - Deep Learning 0.1 documentation. Deep Learning 0.1. LISA Lab.
21. Maitra, Durjoy Sen; Bhattacharya, Ujjwal; Parui, Swapan K. (August 2015). "CNN based common approach to handwritten character recognition of multiple scripts ". 2015 13th International Conference on Document Analysis and Recognition (ICDAR): 1021-1025. doi: 10.1109 / ICDAR.2015.7333916.^
22. Kabir, H. M., Abdar, M., Jalali, S. M. J., Khosravi, A., Atiya, A. F., Nahavandi, S., & Srinivasan, D. (2020). Spinalnet: Deep neural network with gradual input. arXiv preprint arXiv: 2007.03347.
23. Трансферное обучение [Электронный ресурс]. Режим доступа: <https://academy.yandex.ru/posts/transfernoe-obuchenie-pochemu-deep-learning-stal->

доступнее - Дата обращения 12.02.2021

24. B. Zhou, A. Khosla, A. Lapedriza, A. Oliva, and A. Torralba. Learning Deep Features for Discriminative Localization. CVPR'16 (arXiv:1512.04150, 2015).
25. Свёрточные нейронные сети [Электронный ресурс]. Режим доступа: <https://www.machinelearningmastery.ru/demystifying-convolutional-neural-networks-using-class-activation-maps-fe94eda4cef1/> - Дата доступа 05.05.2021
26. Преобразование фурье [Электронный ресурс]. Режим доступа: https://en.wikipedia.org/wiki/Fourier_transform - Дата доступа 01.06.2021
27. K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 770–778.
28. C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, “Going deeper with convolutions,” in Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1–9.
29. K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” arXiv preprint arXiv:1409.1556, 2014
30. L. Yao, E. Poblenz, D. Dagunts, B. Covington, D. Bernard, and K. Lyman, “Learning to diagnose from scratch by exploiting dependencies among labels,” arXiv preprint arXiv:1710.10501, 2017
31. Z. Li, C. Wang, M. Han, Y. Xue, W. Wei, and L.-J. Li, “Thoracic disease identification and localization with limited supervision,” in Computer Vision and Pattern Recognition (CVPR), 2018 IEEE Conference on. IEEE, 2018, pp. 8290–8299.
32. [Keras:[Электронный ресурс] Keras documentation. URL:<https://keras.io/>].
33. [OpenCV: [Электронный ресурс] – URL: <https://opencv.org/>].
34. [Tensorflow:[Электронный ресурс]–URL:<https://www.tensorflow.org/> (Дата обращения: 15.05.2021).].
35. NumPy [Электронный ресурс] Режим доступа: <https://ru.wikipedia.org/wiki/NumPy> - Дата доступа 12.04.2021

36. Resnet [Электронный ресурс] Режим доступа:
<https://www.machinelearningmastery.ru/the-w3h-of-alexnet-vggnet-resnet-and-inception-7baaaecccc96/> - Дата доступа 06.05.2021.
37. “National Institutes of Health Chest X-Ray Dataset”. [Электронный ресурс]
Режим доступа: <https://www.kaggle.com/nih-chest-xrays/data> - Дата доступа 01.01.2021.
38. Трудовой кодекс Российской Федерации от 30.12.2001 N 197-ФЗ
39. СанПиН 1.2.3685-21 "Гигиенические нормативы и требования к обеспечению безопасности и (или) безвредности для человека факторов среды обитания"
40. «ТОИ Р-45-084-01. Типовая инструкция по охране труда при работе на персональном компьютере»
41. ГОСТ 22269-76 «Рабочее место оператора. Взаимное расположение элементов рабочего места»
42. ГОСТ Р 50923-96 «Рабочее место оператора. Общие эргономические требования и требования к производственной среде. Методы измерения. Дисплеи»
43. ГОСТ 12.2.032-78 «Рабочее место при выполнении работ сидя»
44. СанПиН 2.2.4.548-96. «Физические факторы производственной среды. Гигиенические требования к микроклимату производственных помещений»
45. СП 52.13330.2016 «Свод правил естественное и искусственное освещение»
46. СНиП 23-05-95 «Строительные нормы и правила российской федерации естественное и искусственное освещение»
47. СН 2.2.4 «Физические факторы окружающей природной среды. Шум на рабочих местах, в помещениях жилых, общественных зданий и на территории жилой застройки»
48. СН 2.1.8.562-96. «Физические факторы окружающей природной среды. Шум на рабочих местах, в помещениях жилых, общественных зданий и на территории жилой застройки»
49. ГОСТ 12.1.006-84 ССБТ «Электромагнитные поля радиочастот

допустимые уровни на рабочих местах и требования к проведению контроля»

50. ГОСТ 12.1.038-82 Система стандартов безопасности труда (ССБТ).
Электробезопасность. Предельно допустимые значения
напряжений прикосновения и токов.

51. ГОСТ Р 12.1.019-2017 ССБТ «Система стандартов безопасности труда.
Электробезопасность. Общие требования и номенклатура видов защиты»

52. ГОСТ 17.4.3.04-85 «Общие требования к контролю и охране от
загрязнения»

53. ГОСТ Р 53692-2009. «Ресурсосбережение. обращение с отходами. этапы
технологического цикла отходов»

54. ГОСТ 12.1.004-91. «Система стандартов безопасности труда. пожарная
безопасность»

ПРИЛОЖЕНИЕ А

Exploring the Possibilities for Application of Neural Networks in the Automatic Description of X-Ray images

Студент:

| Группа | ФИО | Подпись | Дата |
|--------|------------------------------|---------|------|
| 8BM93 | Скворцов Александр Вадимович | | |

Руководитель ВКР

| Должность | ФИО | Ученая степень, звание | Подпись | Дата |
|-----------|--------------------------|---------------------------|---------|------|
| Доцент | Друки Алексей Алексеевич | | | |

Консультант – лингвист отделения иностранных языков, школы ИШИТР:

| Должность | ФИО | Ученая степень, звание | Подпись | Дата |
|-----------------------|-------------------------|---------------------------|---------|------|
| Старший преподаватель | Розанова Яна Викторовна | | | |

Introduction

The relevance of the work. Currently, the development of neural network technologies and the accumulation of large volumes of medical images open up the

possibility of creating medical images automatic analysis systems. A chest X-ray is a simple and common examination. Its automation will significantly reduce the workload on radiologists, assess the quality of their work and reduce the likelihood of medical errors.

Purpose of work. The research objective is to develop the system for automatic analysis of X-ray images and evaluate the results of its work.

The goals set in the course of the research are:

1. to conduct an analytical review of image classification methods;
2. to search training datasets;
3. to test various architectures of neural networks;
4. to review methods for evaluating their results;
5. to evaluate the results of their work;
6. to compare the results of their work with existing algorithms.

Research subject. Research subject - neural networks used for image classification

1. Medical aspects

Despite the fact that currently methods of radiation diagnostic are widely used,

such as computed tomography (CT), magnetic resonance imaging (MRI) and positron emission tomography (PET), which have a high diagnostic information content, the using of these methods has several disadvantages: pre-existing equipment, specialized software, high radiation exposure. All this increases the cost of examinations, therefore, at present, imaging methods are used only after radiography if a disease is suspected and requires additional examinations. Chest radiography (chest X-ray) is a medical imaging technology that is economical and easy to use. A chest X-ray produces an image of the chest, lung, heart, airways and blood vessels. Using a chest X-ray image, trained radiologist can diagnose conditions such as pneumonia, pneumothorax, interstitial lung disease, heart failure, bone fracture, hiatal hernia and so on. The big advantage of X-ray is the low cost and simple to take. Photographing a chest X-ray is a non-invasive procedure that only takes a few minutes and the result typically comes out within half an hour. Modern digital radiography (DR) machines are quite affordable even in undeveloped regions. Diagnosing chest pathologies from X-ray images has been drawing great attention in clinical and epidemiological studies, since the chest X-ray is one of the common radiology exams in hospitals. A large hospital typically produces over 40,000 chest X-ray per year just from outpatient. Moreover, chest X-ray is a standard screening method in physical examinations that over three hundred million people took in 2014 all over China. This number is still increasing, resulting in hundreds of millions of chest X-ray images per year. Lacking qualified radiologists to review these X-rays is a major challenge in China. Reviewing chest X-rays heavily depends on the experience of radiologists since the image has no spatial information and the overlap of different body parts may hide diseased tissues. Also, many images are difficult to read when the lesions are in low contrast or overlap with large pulmonary vessels. Even worse, each chest X-ray takes a trained radiologist several minutes to review and write the report, and many radiologists have to work over-time, increasing the misdiagnosis due to exhaustion. As a result, the misdiagnosis of X-ray is high. It is reported that about 20% to 50% of lung nodules are missed or misdiagnosed on chest X-rays, while most of them can be detected retrospectively or by a second reviewer.

Inexperienced radiologists are sometimes uncertain about their diagnosis, but they may not have the opportunity to discuss with others. As an X-ray image usually contains multiple pathologies it is challenging for radiologists make diagnosis in a short time [1, 2, 3].

The recent development of artificial intelligence (AI), combined with the accumulating of a vast amount of medical images opens a new opportunity to build an AI based system, computer-aided diagnosis (CAD) system, to automatically analyze such chest X-rays. CAD covers many medical problems, such as automatic vertebrae detection automatic coronary calcium scoring , lymph nodule (LN) detection and interstitial lung disease (ILD) classification. However, most recent CAD systems depends on the high resolution magnetic resonance imaging (MRI) or computed tomography CT) images, while ignoring the plain old X-rays that are much more widely utilized. With the recent success of deep learning automatic disease diagnosis by computer vision techniques can assist radiologists to discover and identify potential pathologies, and further promote the research and applications for computer-aided diagnosis systems. Most existing works formulate this task as multi-label image classification problem which aims to classify an X-ray image into multiple categories (e.g., 14types of pathologies in Chest X-ray 14 dataset).

Significant progress as been achieved by using deep convolutional neural networks, as classification models. For example, Pranav et al. proposes to use a 121-layer convolutional neural network(namely DenseNet-121) as backbone structure, and adopts sigmoid nonlinear function for prediction. Wang et al. proposed an improved framework by integrating transition and global pooling layers into CNN, which is further evaluated the largest Chests-ray 14 data set with good performance. Although promising results have been made in recent years, the difficulties of modeling subtle inter-class distinctions and large intra-class variances still pose grand challenges. For example, the visual appearances (e.g. cloud-like light shadow)of Nodule and Mass are quite similar, and can overlap each other over some parts of chests. As the existing CNN-based networks are mainly designed for general images with larger visual distinctions (e.g., person and airplane in ImageNetdataset) than X-ray images,

it is hard to distinguish these fine-grained pathologies. Besides, the diverse symptoms of Tuberculosis can be often observed from X-ray images, which are hard to confirm the diagnosis not only for automatic algorithms, but even for experienced radiologists. To solve these problems it was proposed to use Multi-attention model [1, 4, 5, 6, 7, 8, 9].

2. Algorithm Description

2.1.1 Classification Problem Statement

The formal statement of the problem is as follows: Let X be the set of descriptions of objects, Y be a finite set of class numbers. There is an unknown target dependence $y^*: X \rightarrow Y$, the values are known only on the object of the final training sample $X_m = \{(x_1, y_1), \dots, (x_m, y_m)\}$. It is required to construct an algorithm $a^*: X \rightarrow Y$ capable of classifying an arbitrary object $x \in X$. A feature is a mapping $f: X \rightarrow D_f$, where D_f is the set of admissible values of a feature. If features f_1, \dots, f_n are given, then the vector $x = (f_1(x), \dots, f_n(x))$ is called a feature description of the object $x \in X$. Feature descriptions can be identified with the objects themselves. In this case, the set $X = D_{f_1} \times \dots \times D_{f_n}$ is called the attribute space. Depending on the type of set D_f , the features are divided into the following types [10]:

1. binary feature: $D_f = \{0, 1\}$;
2. nominal feature: D_f - finite set;
3. ordinal attribute: D_f - finite ordered set;
4. quantitative feature: D_f - set of real numbers.

2.1.2 Multi-class classification

Multiclass classification should not be confused with multi-label classification, where multiple labels are to be predicted for each instance. In machine learning, multiclass or multinomial classification is the problem of classifying instances into one of three or more classes (classifying instances into one of two classes is called binary classification) [11,12].

While many classification algorithms (notably multinomial logistic regression)

naturally permit the use of more than two classes, some are by nature binary algorithms; these can, however, be turned into multinomial classifiers by a variety of strategies. Existing methods of multiclass classification can be divided into reduction to binary classification or the extension of binary classification to multiclass classification. When reducing to the work of several binary classifiers, the training options "one against one" and "one against all" are used. As the error functions in neural networks used by the multiclass classification, categorical cross-entropy with the Softmax activation function is used [11,12].

2.1.3 Multi-label classification

In machine learning, multi-label classification and the strongly related problem of multi-output classification are variants of the classification problem where multiple labels may be assigned to each instance. Multi-label classification is a generalization of multiclass classification, which is the single-label problem of categorizing instances into precisely one of more than two classes; in the multi-label problem there is no constraint on how many of the classes the instance can be assigned to [13,14].

Formally, multi-label classification is the problem of finding a model that maps inputs x to binary vectors y (assigning a value of 0 or 1 for each element (label) in y). Several problem transformation methods exist for multi-label classification, and can be roughly broken down into: transformation into binary classification problems; transformation into multi-class classification problem; ensemble methods. In case the classification by several labels is carried out by one neural network with several outputs, binary cross-entropy is used as a loss function [13,14].

2.2 Fully connected and convolutional neural networks.

A fully connected feedforward neural network is a network in which a neuron is

connected to all other neurons located in adjacent layers (See the figure 1 below).

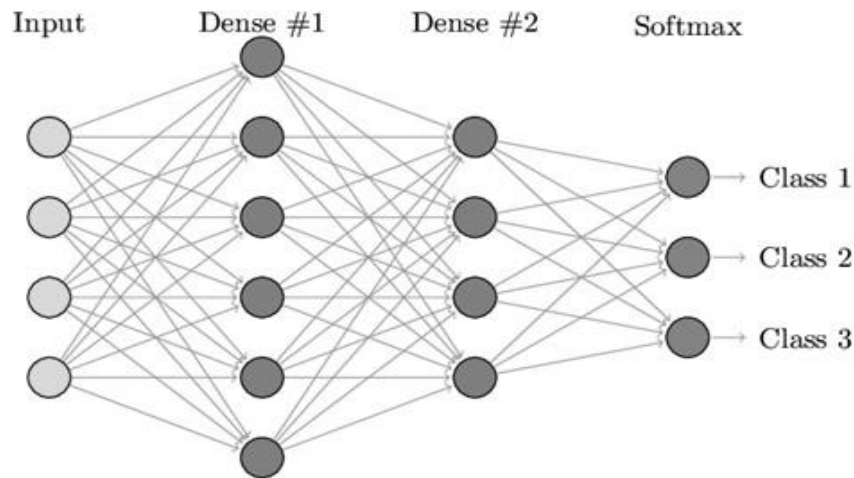


Fig. 1 Fully connected neural network

The left side of the image shows the input layer to which the signal arrives. To the right are two hidden layers, and the rightmost neuron layer is the output layer. This network might solve the problem of recognizing multiple classes and multiple labels [15,16].

When processing images and, in particular, recognizing objects in photographs, appears the problem of a large amount of data. For an example with pictures from ImageNet in each neural network system, there are about $256 * 256 * 3 = 196608$ weights. For a complete classification, it is necessary to have at least several such neurons. The solution to this problem is the use of a neural network of a special architecture used for image classification - a convolutional neural network. The layers of this neural network are located in three dimensions, which are characteristic of the RGB format. The neurons in a layer are connected only with a certain area in the previous layer, and not with all as in a fully connected network. Convolutional neural networks have the best image recognition results at the moment. The main layers that are used in a convolutional network are: a convolutional layer; a down sampling layer and a fully connected layer representing the fully connected neural network already described above. The convolutional layer is the main layer in CNN. This layer is based on the convolution operation, which consists in the fact that a small matrix is traversed over all input data, creating a new value for a certain number of pixels.

Such a matrix is called the convolution kernel, its peculiarity is that the weights are called such a matrix during training and are unknown. The down sampling layer or pooling layer reduces the feature matrix to a smaller matrix. This transformation is done on unique, non-overlapping areas. Usually, one pixel is selected from a 2x2 rectangle, the maximum is maximum. This removes minor details. There are subsampling not only with a maximization function, but also with a mean or L2 normalization function. In a fully connected layer, the probability of belonging to a class is calculated using the available (See the figure 2 below) [17].

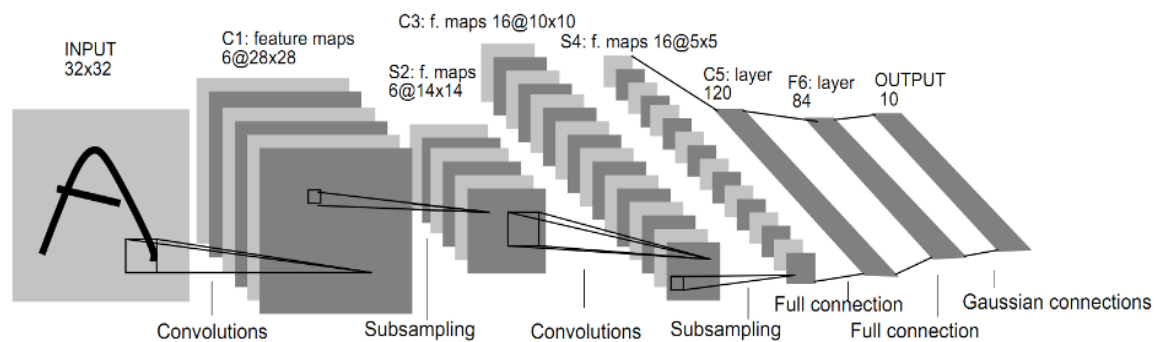


Fig. 2 CNN architecture

2.3 Transfer learning

The idea of transfer learning is based on the fact that the knowledge accumulated in a model prepared for one task can be transferred to another model to help in making predictions for another, related task. Experiments have shown that the accuracy of neural networks during transfer learning increased both in the first epoch (before any learning, i. e., compared to the standard random distribution of weights) and at the end of the learning process [18,19,20].

There are various approaches to transfer learning. The most widely used is fine tuning (fine tuning). This approach uses a pretrained model in which the last layers are removed or retrained. In neural networks, base layers focus on simple, general patterns, while the last layers focus on more specific patterns for classification or regression problems. Through this process, a developer can train a new model in a reasonable amount of time. Deep learning typically requires large amounts of labeled

data. In many areas, such data does not exist. Transfer learning can solve this problem. For example, a team at Harvard Medical School has created a model that can predict long-term mortality from chest X-rays, including those not associated with cancer. Even though the researchers had a dataset of roughly 50,000 tagged images, they couldn't train their own convolutional neural network from scratch. Instead, they used a prepared Inception-v4 model (which trains on a dataset of over 14 million ImageNet images) and used transfer learning and minor architectural modifications to adapt the model to their dataset. As a result, their neural network learned to calculate the level of risk from one image of the patient's chest. When Google developed its Xception image classification model, two versions were prepared: one on the ImageNet dataset (14 million images) and the other on the JFT dataset (350 million images). Training on 60 NVIDIA K80 GPUs with various optimizations took three days to run one experiment with ImageNet. The JFT experiment took over a month [20].

2.4 Class activation maps

As the performance of machine learning systems increases, the interpretability of systems gradually decreases. This trend is more visible in deep learning algorithms containing millions of trainable parameters and hundreds of layers. This makes them extremely difficult to interpret compared to basic machine learning algorithms such as linear regression, K nearest neighbors, decision tree, etc. Such, neural networks are a typical example of a Black Box that receives data from users and produces results without any causal information that led to such a conclusion. In applications where the interpretability of the results is very important, the nature of the black box discourages implementation. This is especially true in the field of medicine, where the patient's life depends on diagnosis. Various efforts are being made to solve the problem of interpretability and achieve the level of interpretable AI. In the case of CNN, various rendering techniques have been discovered, and one of them is class activation maps (CAMs). The class activation map for a specific category indicates the discriminatory area used by CNN to identify the category. The neural network

consists of a large number of convolutional layers and, just before the final output layer, a global average merge is performed. The features thus obtained are fed into a fully connected layer having a softmax activation that gives the desired output. We can determine the importance of image regions by projecting the weights of the output layer onto the convolutional feature maps obtained from the last Convolutional layer. The dot product of the extracted weights from the last layer and feature map is calculated to create a class activation map. The class activation map is enhanced using bilinear interpolation and superimposed on the input image to show the regions that the CNN model (See the figure 3 below) [21,22].

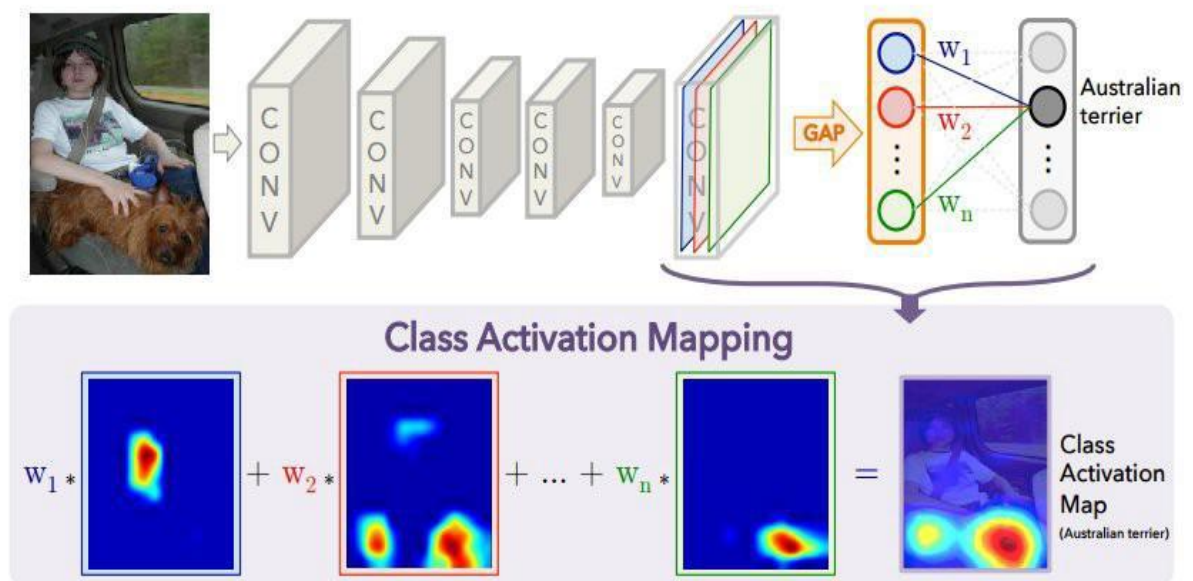




Fig. 3 Class activation map

3. Approaches to chest radiographs analysis based on the neural networks application


The following solutions are currently proposed for the automatic analysis of x-ray images. Wang et.al proposed an improved framework by integrating transition and global pooling layers into CNN, which is further evaluated the largest ChestX-ray 14 dataset with good performance. Besides, the ResNet neural network outperformed other popular convolutional neural network, e.g. GoogLeNet, VGGNet and AlexNet, in terms of the AUC metric (See the figure 4 below) [23,24,25].




(a) Patient with multifocal community acquired pneumonia. The model correctly detects the airspace disease in the left lower and right upper lobes to arrive at the pneumonia diagnosis.



(b) Patient with a left lung nodule. The model identifies the left lower lobe lung nodule and correctly classifies the pathology.




(c) Patient with primary lung malignancy and two large masses, one in the left lower lobe and one in the right upper lobe adjacent to the mediastinum. The model correctly identifies both masses in the X-ray.



(d) Patient with a right-sided pneumothorax and chest tube. The model detects the abnormal lung to correctly predict the presence of pneumothorax (collapsed lung).



(e) Patient with a large right pleural effusion (fluid in the pleural space). The model correctly labels the effusion and focuses on the right lower chest.



(f) Patient with congestive heart failure and cardiomegaly (enlarged heart). The model correctly identifies the enlarged cardiac silhouette.

Fig. 5 CheXNet results of work. Under the images is the conclusion of a radiologist

Yao et. al proposes to combine CNN with a type of recurrent neural networks (RNN) for diagnosing chest images, through which the dependencies among different pathology categories can be captured (See the figure 6 below) [26].

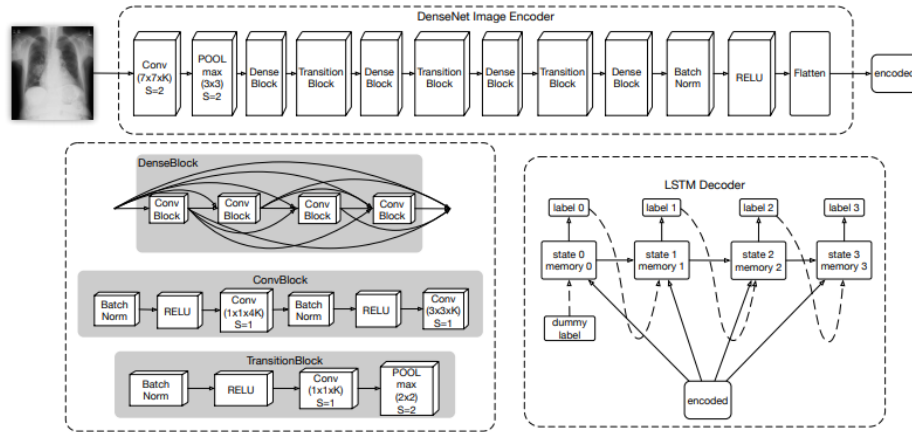


Fig. 6 Yao et. al scheme [26]

Li et al. used a pre-trained ResNet to extract features and divided them into patches. They passed the extracted patches through a fully-convolutional classification CNN to obtain a disease probability map which is supervised by both image-level annotations and limited pixel-level annotations. The input image is firstly processed by a CNN. The patch slicing layer resizes the convolutional features from the CNN using max-pooling or bilinear interpolation. These regions are then passed to a fully-convolutional recognition network. During training, used multi-instance learning assumption to formulate two types of images; during testing, the model predicts both labels and class-specific localization (See the figure 7 below) [27].

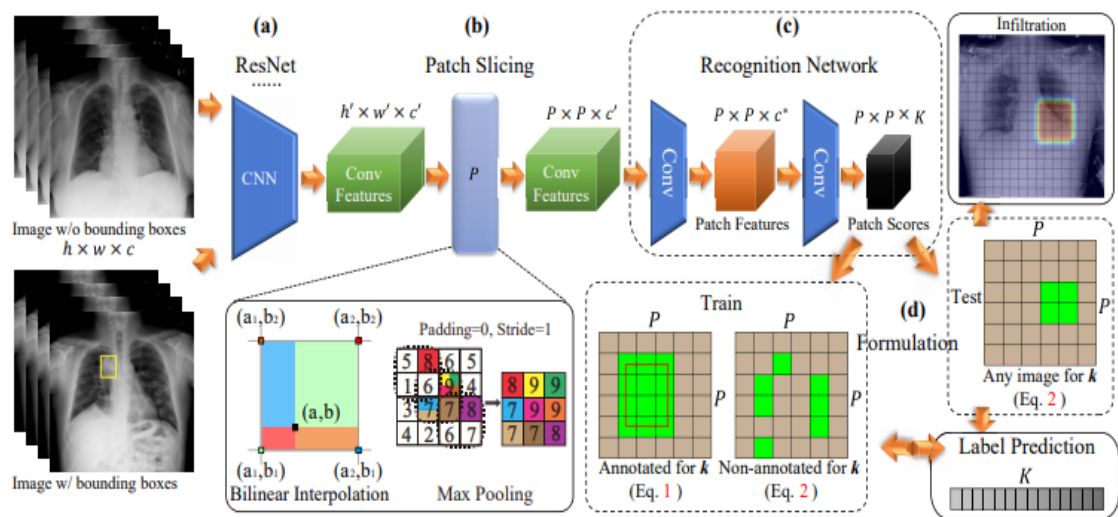


Fig. 7 Li et. al scheme [27]

Zhicheng Huang, Dongmei Fu propose a multi-attention convolutional neural network to detect chest pathologies in X-ray images. The proposed approach consists of three parts of the sub-network: a fully convolution network (FCN) for deep feature extraction, which is suitable for spatial prediction and getting more specific regions for each class; a multi-attention network for discriminative feature learning and a top-k pooling module to select relevant regions to getting the scalar for final prediction. The figure below illustrates all the elements of this network: (a) is an input image; (b) is a FCN which can encode spatial information into deep feature maps; (c) is a group of multi-attention layer to produce class-specific attention maps for localizing pathologies and extracting discriminative features to each category; (d) is a channel-wise pooling layer to combine the feature captured from different channels for each category; (e) is a top-k pooling layer which aims to select the high confidence points of each class for the final prediction; (f) is a classification layer to predict the presents of each category by sigmoid activation function (See the figure 8 below) [9].

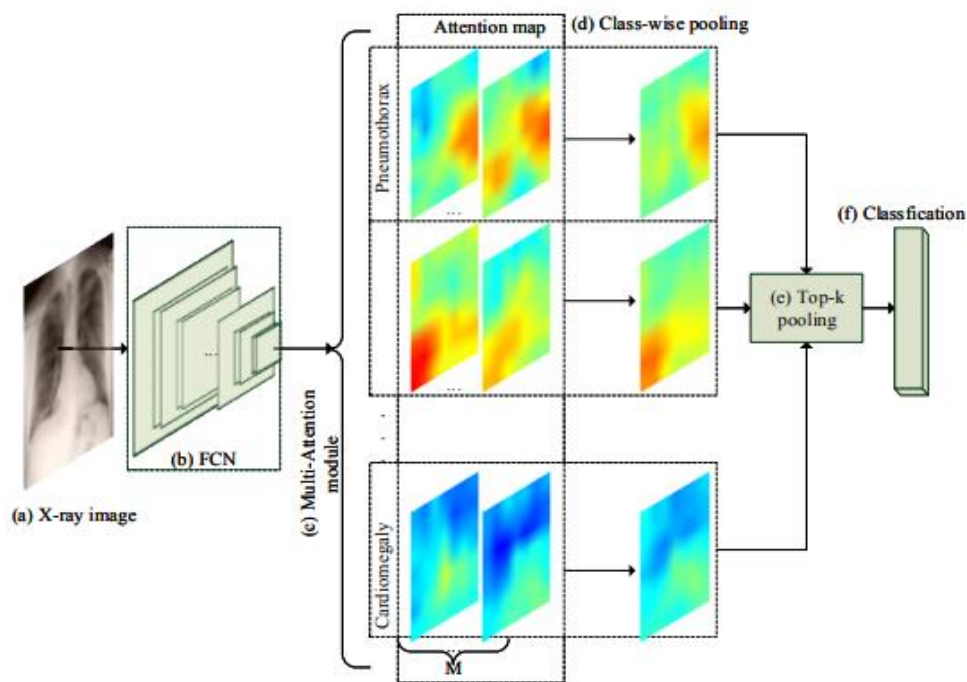


Fig. 8 Zhicheng Huang, Dongmei Fu scheme [9]

Finally, most recent work from Yan et.al. combined squeeze-and-excitation

blocks with DenseNet to boost the model performance . Besides, they also used multi-map transfer and max-min pooling for classification and localizing suspicious lesion regions (See the figure 9) [6].

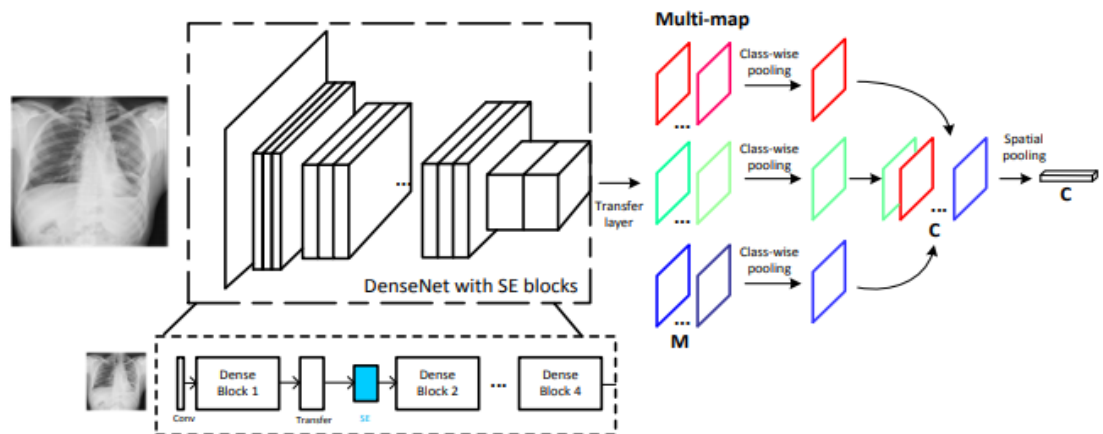


Fig. 9 Yan et.al. scheme [6]

Results

The results obtained are in line with the previously set goals.

Datasets were searched. The NIH Chest X-ray Dataset, with over 100,000 chest images with 15 classes, was selected.

The problem of automatic analysis of X-ray images was formulated as a classification problem. A comparison was made between the Resnet50 and VGG19 architectures in the context of the problem of X-ray image analysis. The benefits of VGG19 have been shown. The classifiers used are based on the VGG19 architecture. Several approaches were tested: training 14 ternary classifiers “norm, target pathology, other pathology”; testing the classifier "Norm, pathology"; testing a classifier with 15 classes (multi label classification); testing a classifier with 15 classes with only single labels. Image preprocessing was tested which using fast Fourier transform and image inversion. The training of classifiers was carried out both with randomly initialized weights and in various versions of transfer learning. For all classifiers, an analysis of the work was carried out using class activation maps.

System errors in the dataset and the problems of detecting insignificant features by neural networks were described. Was formulated recommendations for creating systems of automatic analysis of X-ray images.